



TESIS - TL142308

**Prediksi Umur Kelelahan Komposit Yang
Dipengaruhi *Variable Amplitude Loading*
Menggunakan *Artificial Neural Network*
Dengan Algoritma *Training Metaheuristik***

MUH NUR ROHMAN
NRP. 02511550012004

DOSEN PEMBIMBING
Mas Irfan P. H., ST, MSc, PhD
Dr. Agung Purniawan, ST, MEng

PROGRAM STUDI MAGISTER
DEPARTEMEN TEKNIK MATERIAL
FAKULTAS TEKNOLOGI INDUSTRI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018



THESIS - TL142308

Prediction Of Composite Fatigue Life Under Variable Amplitude Loading Using Artificial Neural Network Trained By Metaheuristic Algorithm

MUH NUR ROHMAN
NRP. 02511550012004

SUPERVISORS
Mas Irfan P. H., ST, MSc, PhD
Dr. Agung Purniawan, ST, MEng

MAGISTER PROGRAM
MATERIALS ENGINEERING DEPARTMENT
FACULTY OF INDUSTRIAL TECHNOLOGY
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Teknik (M.T.)

di

Institut Teknologi Sepuluh Nopember Surabaya

Oleh:

Muh Nur Rohman

NRP. 02511550012004

Tanggal Ujian : 10 Januari 2018

Periode Wisuda : Semester Gasal 2017/2018

Disetujui oleh:

1. Mas Irfan P. Hidayat, ST, MSc, Ph.D
NIP: 197610272003121001

(Pembimbing I)

2. Dr. Agung Purniawan, ST, MEng
NIP: 197605282002121003

(Pembimbing II)

3. Lukman Noerochim, ST, MSc.Eng, Ph.D
NIP: 197703132003121001

(Penguji)

4. Sigit Tri Wicaksono, SSi, MSi, Ph.D
NIP: 197801132002121003

(Penguji)

5. Dr. Widyastuti, SSi, MSi
NIP: 197906202006042001

(Penguji)



Dekan Fakultas Teknologi Industri,

Dr. Bambang Lelono Widjiantoro, ST, MT

NIP: 196905071995121001

(Halaman ini sengaja dikosongkan)

Presiksi Umur Kelelahan Komposit Yang Dipengaruhi *Variable Amplitude Loading* Menggunakan *Artificial Neural Network* Dengan Algoritma Training Metaheuristik

Nama : Muh Nur Rohman
NRP : 02511550012004
Pembimbing : Mas Irfan P. H., ST, MSc, PhD
Ko - pembimbing : Dr. Agung Purniawan, ST, MEng

ABSTRAK

Gradient-based search sudah banyak digunakan sebagai algoritma optimasi pada *Artificial Neural Network* (NN) berbasis *Multilayer Perceptrons* (MLP) untuk prediksi umur kelelahan komposit berbasis polimer. Akhir-akhir ini metode optimasi yang lebih baru yaitu metaheuristik telah banyak digunakan untuk optimasi NN, namun aplikasinya masih di luar bidang prediksi umur kelelahan komposit. Pada penelitian ini telah dikembangkan model NN berbasis MLP dengan satu *hidden layer* untuk prediksi umur kelelahan komposit berbasis polimer dengan *variable amplitude loading*. Bobot dan bias didapatkan dengan tiga metode optimasi metaheuristik secara murni, yaitu *Genetic Algorithm* (GA), *Differential Evolution* (DE) dan *Particle Swarm Optimization* (PSO). Jumlah data kelelahan yang terbatas digunakan untuk training. Tiga parameter pembebanan siklik yaitu tegangan maksimum dan minimum dan *stress ratio* (*R*) digunakan sebagai input NN dan log-umur kelelahan sebagai output. Kinerja model NN ditunjukkan dengan *MSE*, R^2 dan persentase jumlah data yang bisa digunakan dengan mempertimbangkan kurva *P-S-N* hasil eksperimen. Setiap prediksi umur kelelahan didapatkan dengan mengambil nilai rata-rata dari tigapuluh kali percobaan yang dilakukan secara independen. Simulasi dengan *E-glass fabrics/epoxy* (*layups* $[(\pm 45)/(0)_2]_s$) menggunakan 33% dari jumlah data eksperimen untuk training dan 67% untuk testing. Model NN terbaik adalah MLP-DE dengan jumlah *hidden nodes* 25-30 berdasarkan tiga ukuran kinerjanya, yaitu sebanyak 93.75% dari jumlah data prediksi bisa digunakan, serta nilai *MSE* dan R^2 secara berurutan sebesar 0.138 dan 0.9532. Dengan nilai rata-rata R^2 0.9370-0.9532, ketiga model NN dalam penelitian ini menunjukkan akurasi yang tinggi. Simulasi dengan *E-glass/polyester* (*layups* $[90/0/\pm 45/0]_s$) menggunakan 22% dari jumlah data eksperimen untuk training dan 78% untuk testing. MLP-GA dengan jumlah *hidden nodes* 25-30 lebih disukai karena menunjukkan jumlah data terbanyak yang bisa digunakan, yaitu 74.76%. Rata-rata *MSE* dan R^2 dari ketiga model NN dalam penelitian ini menunjukkan nilai yang hampir sama, secara berurutan sebesar 0.2445-0.2490 dan 0.8556-0.8575. Ketiga model NN dalam penelitian ini menunjukkan akurasi yang cukup tinggi dengan mempertimbangkan nilai rata-rata R^2 . Akurasi model NN-metaheuristik pada penelitian ini secara umum *comparable* dengan NN-*gradient-based*, kecuali MLP-PSO pada *E-glass fabrics/epoxy* yang menghasilkan akurasi yang lebih rendah.

Kata kunci: Komposit, Umur kelelahan, *variable amplitude loading*, *neural networks*, metaheuristik

(Halaman ini sengaja dikosongkan)

Prediction of Composite Fatigue Life Under Variable Amplitude Loading Using Artificial Neural Network Trained By Metaheuristic Algorithm

By : Muh Nur Rohman
Student Identity Number : 02511550012004
Supervisor : Mas Irfan P. H., ST, MSc, PhD
Co - Supervisor : Dr. Agung Purniawan, ST, MEng

ABSTRACT

Gradient-based search technique have been used in many research as an algorithm to optimize Multilayer Perceptrons (MLP) based Artificial Neural Network (NN) for fatigue life prediction of polymeric-base. The later optimization method of methaheuristics have been used to optimize the NN, however the applications are still beyond the field of composite fatigue life prediction. In present research, we have developed NN model based on MLP with single layer to predict fatigue life of polymeric-base composite under variable amplitude loading. The weights and bias were obtained by utilizing three methods of methaheuristic optimization purely, i.e. Genetic Algorithm (GA), Differential Evolution (DE) and Particle Swarm Optimization (PSO). Limited number of fatigue data were used in trainings. Three parameters of cyclic loading i.e. maximum and minimum stress and stress ratios (R) were used as NN input, on the other side, log-fatigue life were used as output NN. The performance of NN models were quantified by MSE , R^2 and percentage of number of fatigue data that can be used with respect to $P-S-N$ curve which generated from experimental results. A single prediction of fatigue life was taken from the average value from thirty times of independent trials. 33% of number of experimental fatigue data of E-glass fabrics/epoxy (layups $[(\pm 45)/(0)_2]_s$) were used for training and the 67% for testing. From simulation results found that MLP-DE with 25-30 hidden nodes is the best NN model with respect to those three performance indicators, i.e., 93.75% of total number of prediction data are can be used, with MSE and R^2 of 0.138 and 0.9532, respectively. With respect to average of R^2 of 0.9370-0.9532, the three of NN models in this research exhibit high accuracy. On the other side, 22% of number of experimental fatigue data of E-glass/polyester (layups $[90/0/\pm 45/0]_s$) were used for training and 78% for testing. MLP-GA with 25-30 hidden nodes is preferred with respect to that 74.76% of the total number of prediction data are can be used. The average of MSE and R^2 of NN models exhibit almost similar values, i.e. 0.2445-0.2490 and 0.8556-0.8575, respectively. With respect to average of R^2 , the three NN models in this research exhibit accuracy of reasonably high. Generally, the accuracy of NN-metaheuristic models in this research are comparable with NN-*gradient-based*, with exception of MLP-PSO for *E-glass fabrics/epoxy* which have lower in accuracy.

Keywords: Composite, Fatigue life, variable amplitude loading, neural networks, metaheuristic

(This page is intentionally blank)

KATA PENGANTAR

Puji syukur kehadiran Allah SWT, atas segala rahmat dan karunia-Nya dan sholawat serta salam semoga selalu terlimpahkan kepada junjungan nabi Muhammad, sehingga penulis dapat menyelesaikan laporan tesis ini dengan judul “Presiksi Umur Kelelahan Komposit Yang Dipengaruhi *Variable Amplitude Loading* Menggunakan *Artificial Neural Network* Dengan Algoritma Training Metaheuristik”, Sebagai salah satu syarat untuk Memenuhi Persyaratan Akademik Untuk Memperoleh Magister Teknik (M.T) Pada Program Studi Magister Teknik Material Fakultas Teknik Industri Institut Teknologi Sepuluh Nopember Surabaya tahun 2018.

Pada kesempatan ini penulis mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu penyusunan laporan Tugas Akhir ini diantaranya kepada :

1. Bapak Mas Irfan P. Hidayat, ST, MSc, PhD selaku dosen pembimbing yang telah mengenalkan dunia pemodelan dengan *artificial neural network*, optimasi metaheuristik dan kelelahan komposit, serta petunjuk dan bimbingannya dalam metodologi dan penulisan, serta segala upaya dan dorongannya untuk membantu penulis dalam menyelesaikan tesis ini tepat waktu. Sekiranya hanya Allah SWT yang mampu membalas budi baik Bapak.
2. Bapak Dr. Agung Purniawan, ST, MEng selaku dosen ko-pembimbing atas segala bimbingan, petunjuk, saran dalam menyelesaikan tesis ini.
3. Istriku tercinta, Luki Trihardani, atas segala support dan semangat yang tak terkira.
4. Kedua orang tua tercinta, Bapak H. Endang Yusuf dan almarhumah ibu Hj. Ngatinah yang telah mendukung dan mencurahkan doa, usaha dan waktu.
5. Bapak H. Moch. Heroe dan Ibu Hj. Siti Indiyah atas segala doa dan bantuannya.
6. Bapak Lukman Noerochim, ST, MSc.Eng, Ph.D, Dr. Eng. Hosta A. ST. MSc, Sigit Tri Wicaksono, SSi, MSi, Ph.D, Dr. Widyastuti, SSi, MSi dan Ibu Diah Susanti, ST, MT, PhD selaku dosen penguji pada seminar proposal, kemajuan tesis dan sidang tesis. Terimakasih atas segala saran yang diberikan.

7. Bapak Lukman Noerochim, ST, MSc.Eng, PhD selaku Kaprodi Pascasarjana Teknik Material ITS atas semua bantuan dan kemudahan dalam perkuliahan dan proses tesis.
8. Semua dosen program pascasarjana Teknik Material ITS atas ilmu yang telah dibagikan. Semoga Allah SWT melimpahkan rahmat kepada Bapak-bapak dan Ibu-ibu sekalian.
9. Staff admin pascasarjana Teknik Material ITS yang telah banyak membantu selama masa belajar.
10. Teman-teman mahasiswa pascasarjana Teknik Material ITS yang telah banyak membantu selama masa perkuliahan.
11. Semua pihak yang tidak dapat penulis sebutkan satu-persatu yang telah banyak memberi dorongan dan bantuan dalam menyelesaikan thesis ini baik secara langsung maupun tidak langsung.

Menyadari atas keterbatasan pengetahuan dan penelitian sehingga dimungkinkan ada kekeliruan dan kesalahan yang tidak sengaja. Oleh karena itu kritik dan saran yang membangun sangat dibutuhkan guna perbaikan dan pengembangan lebih lanjut. Semoga laporan ini dapat bermanfaat dan memenuhi apa yang diharapkan.

Surabaya, Januari 2018

Muh Nur Rohaman

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN TESIS.....	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxvii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	2
1.3 Asumsi	2
1.4 Lingkup Penelitian	2
1.5 Tujuan Penelitian	2
1.6 Manfaat Penelitian	3
BAB 2 KAJIAN PUSTAKA DAN DASAR TEORI	5
2.1 Penelitian Prediksi Umur Kelelahan Komposit Dengan <i>Artificial Neural Network</i> (NN).....	5
2.2 Kelelahan Material Komposit	7
2.3 Kelelahan <i>Constant Amplitude Loading</i>	8
2.4 Kelelahan <i>Variable Amplitude Loading</i>	9
2.5 <i>Constant life diagram (CLD)</i>	11
2.6 Mekanisme kelelahan material komposit	12
2.6.1 Degradasi kekuatan (<i>strength</i>) dan kekakuan (<i>stiffness</i>)	12
2.6.2 Kelelahan material polymer.....	14
2.7 Karakteristik material komposit	15
2.7.1 Matrix komposit	16
2.7.2 Serat penguat.....	16
2.7.3 Sifat kelelahan komposit	16
2.7.4 Anisotropi komposit	18
2.7.5 Pengaruh <i>fibre volume fraction</i> (arah pembebanan longitudinal)	18
2.7.6 Pengaruh <i>fibre volume fraction</i> (arah pembebanan transversal)	21
2.7.7 Pengaruh <i>stress ratio</i>	22
2.9 <i>Artificial Neural Network</i> (NN)	25
2.9.1 Proses <i>learning</i>	26
2.9.2 <i>Multilayer Perceptrons</i> (MLP)	26
2.10 Algoritma Optimasi Metaheuristik	29
2.10.1 <i>Genetic Algorithm</i> (GA)	30
2.10.1.1 Pembangkitan populasi awal	31

2.10.1.2	Evaluasi <i>fitness</i>	31
2.10.1.3	Elitisme	31
2.10.1.4	Seleksi kromosom	32
2.10.1.5	Kawin silang	32
2.10.1.6	Mutasi	33
2.10.2	<i>Differential Evolution</i> (DE)	33
2.10.2.1	Pembangkitan populasi awal	34
2.10.2.2	Evaluasi <i>fitness</i>	35
2.10.2.3	Mutasi	35
2.10.2.4	Kawin silang	35
2.10.2.5	Seleksi	36
2.10.2.6	Mengendalikan faktor Cr dan F	36
2.10.2.7	Menangan pelanggaran batas	36
2.10.3	<i>Particle Swarm Optimization</i> (PSO)	37
2.10.3.1	Pembangkitan awal populasi (posisi ke-nol dan kecepatan ke-nol).....	38
2.10.3.2	Evaluasi <i>fitness</i> (awal).....	38
2.10.3.3	$Pbest$ dan $Gbest$	38
2.10.3.4	Kecepatan partikel V_j	39
2.10.3.5	Posisi partikel X_j	39
2.10.3.6	Evaluasi <i>fitness</i> akhir.....	40
2.10.3.7	Pengaruh nilai learning rate c_1 dan c_2	40
2.10.3.8	Menangani pelanggaran batas kecepatan.....	41
2.10.3.9	Menangani pelanggaran batas posisi partikel.....	41
BAB 3	METODE PENELITIAN	43
3.1	Diagram alir pemodelan NN	43
3.2	Parameter kelelahan	46
3.3	Material dan data kelelahan untuk validasi model	46
3.4	Penentuan data kelelahan untuk training dan testing	48
3.5	Pemodelan NN.....	49
3.6	Training NN	50
3.7	Akurasi model NN	52
3.8	Analisa sensitivitas.....	55
3.9	Realisasi	55
BAB 4	HASIL SIMULASI DAN PEMBAHASAN	57
4.1	Parameter NN, GA, DE dan PSO	57
4.2	Pemilihan Arsitektur NN Berdasarkan Jumlah Hidden Nodes Yang Optimal	58
4.3	Simulasi Dengan <i>Hybrid</i> MLP-GA	60
4.3.1	Hasil Simulasi Dengan Material 1	60
4.3.1.1	Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental	60
4.3.1.2	Akurasi prediksi model NN	63
4.3.1.3	Model NN terbaik.....	67
4.3.2	Hasil Simulasi Dengan Material 2	68

4.3.2.1	Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental	68
4.3.2.2	Akurasi prediksi model NN	73
4.3.2.3	Model NN terbaik.....	76
4.4	Simulasi Dengan <i>Hybrid</i> MLP-DE	77
4.4.1	Hasil Simulasi Dengan Material 1	77
4.4.1.1	Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental	77
4.4.1.2	Akurasi prediksi model NN	90
4.4.1.3	Model NN terbaik.....	84
4.4.2	Hasil Simulasi Dengan Material 2	85
4.4.2.1	Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental	85
4.4.2.2	Akurasi prediksi model NN	90
4.4.2.3	Model NN terbaik.....	94
4.5	Simulasi Dengan <i>Hybrid</i> MLP-PSO	95
4.5.1	Hasil Simulasi Dengan Material 1	95
4.5.1.1	Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental	95
4.5.1.2	Akurasi prediksi model NN	98
4.5.1.3	Model NN terbaik.....	102
4.5.2	Hasil Simulasi Dengan Material 2	103
4.5.2.1	Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental	103
4.5.2.2	Akurasi prediksi model NN	107
4.5.2.3	Model NN terbaik.....	111
4.6	Akurasi Model NN Berdasarkan Banyaknya Hasil Prediksi Yang Bisa Digunakan	112
4.7	Analisa Sensitivitas <i>Hybrid</i> MLP-GA	117
4.7.1	Analisa Sensitifitas Hasil Simulasi Material 1.....	118
4.7.2	Analisa Sensitifitas Hasil Simulasi Material 2	123
4.8	Analisa Sensitivitas <i>Hybrid</i> MLP-DE	128
4.8.1	Analisa Sensitifitas Hasil Simulasi Material 1	128
4.8.2	Analisa Sensitifitas Hasil Simulasi Material 2	133
4.9	Analisa Sensitivitas <i>Hybrid</i> MLP-PSO	139
4.9.1	Analisa Sensitifitas Hasil Simulasi Material 1	139
4.9.2	Analisa Sensitifitas Hasil Simulasi Material 2	144
4.10	Perbandingan Performa Metode Optimasi GA vs. DE vs. PSO	150
4.11	Perbandingan Kinerja NN-Metaheuristik Dengan NN-Gradient- Based	153
	BAB 5 KESIMPULAN DAN SARAN	155
5.1	Kesimpulan	155
5.2	Saran	156
	DAFTAR PUSTAKA	157

LAMPIRAN 1: Review Data Kelelahan Komposit Sandia National Laboratories / Montana State University / Department of Energy (SNL/MSU/DOE).....	163
LAMPIRAN 2: Kurva P-S-N Data Hasil Eksperimen Dan Umur Kelelahan Prediksi NN Yang Diterima	181
LAMPIRAN 3: Teori Test ANOVA Dan Tukey (Minitab)	199

DAFTAR GAMBAR

Gambar 2.1. Terminologi kelelahan secara umum	8
Gambar 2.2. Terminologi dasar kelelahan	9
Gambar 2.3. Klasifikasi pembebanan pada uji kelelahan	9
Gambar 2.4. Pola pembebanan siklik yang tidak beraturan	10
Gambar 2.5. Skematik <i>counting method</i>	10
Gambar 2.6. Contoh CLD	11
Gambar 2.7. Ilustrasi pembebanan dengan <i>variable amplitude</i> dan <i>variable stress ratio (R)</i>	12
Gambar 2.8. Beberapa contoh kerusakan yang terjadi pada fibre reinforced composite (ilustratif)	13
Gambar 2.9. <i>Residual strength</i> dari komposit graphite/epoxy laminat setelah mengalami kerusakan akibat kelelahan	13
Gambar 2.10. <i>Residual stiffness</i> dari komposit graphite/epoxy laminat setelah mengalami kerusakan akibat kelelahan	14
Gambar 2.11. Ilustrasi kurva <i>hysteresis</i> sebuah siklus <i>stress-strain</i> pada material <i>viscoelastic</i>	15
Gambar 2.12. Properties kelelahan material yang digunakan dalam industri kapal terbang	17
Gambar 2.13. Tegangan maksimum unidireksional sebagai fungsi <i>fibre volume fraction</i>	19
Gambar 2.14. Hubungan antara rasio beban yang ditanggung fiber terhadap rasio kekakuan dan fraksi volume fiber	20
Gambar 2.15. Pengaruh fraksi beban fiber terhadap rasio kekakuan komposit pada arah pembebanan longitudinal (EL) dan transversal (ET).....	21
Gambar 2.16. Kelelahan material GFRP $[0/(\pm 45)_2/0]_T$, yang menerima beban dengan arah on-axis (a) dan off-axis (b)	23
Gambar 2.17. (a) Model struktur jaringan syaraf makhluk hidup. (b) Model NN yang terinspirasi oleh model struktur jaringan syaraf makhluk hidup	25
Gambar 2.18. Arsitektur <i>MLP</i> dengan satu hidden layer dan single output	26
Gambar 2.19. Diagram alir <i>genetic algorithm</i> (GA)	30
Gambar 2.20. Ilustrasi proses elitisme	32
Gambar 2.21. Diagram alir algoritma DE	34
Gambar 2.22. Diagram alir algoritma PSO	37
Gambar 2.23. Area kandidat posisi baru partikel $X^{(i-1)}$ (tanda silang) dengan P_{best} (tanda bintang) dan G_{best} (tanda kotak) dari (A) $c_1 = c_2 = 1$ (B) $c_1 = c_2 = 2$	40
Gambar 3.1. Diagram alir pemodelan <i>hybrid</i> MLP-GA.....	43
Gambar 3.2. Diagram alir pemodelan <i>hybrid</i> MLP-DE.....	44
Gambar 3.3. Diagram alir pemodelan <i>hybrid</i> MLP-PSO.....	45
Gambar 3.4. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN... ..	53
Gambar 4.1. Ilustrasi <i>overtraining</i>	59

Gambar 4.2. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 1, dengan training Set 3, iterasi maksimum 200 dan jumlah hidden nodes = 27	62
Gambar 4.3. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 1, dengan training Set 2, iterasi maksimum 50 dan jumlah hidden nodes = 8	63
Gambar 4.4. Plot nilai <i>MSE</i> (<i>average</i> , <i>minimum</i> dan <i>maximum</i>) dan <i>error bar</i> yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-GA untuk material 1	64
Gambar 4.5. Plot nilai <i>MSE</i> dan <i>error bar</i> yang menunjukkan <i>confidence interval</i> dengan $\alpha = 0.05$, dari akurasi MLP-GA untuk material 1	64
Gambar 4.6. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (<i>average</i>) dan minimum) untuk tiap-tiap <i>stress ratio</i> (<i>R</i>) dari MLP-GA dengan jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 1, dengan training set 3 dan iterasi maksimum 200	65
Gambar 4.7. Plot nilai <i>MSE</i> testing terhadap jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 1, dengan training set 3 dan iterasi maksimum 200...	66
Gambar 4.8. Plot akurasi dalam R^2 dari model no. 9 dengan jumlah hidden nodes 25 hingga 30.	68
Gambar 4.9. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 2, dengan training Set 1, iterasi maksimum 100 dan jumlah hidden nodes = 22	70
Gambar 4.10. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 2, dengan training Set 1, iterasi maksimum 50 dan jumlah hidden nodes = 6	72
Gambar 4.11. Plot nilai <i>MSE</i> (<i>average</i> , <i>minimum</i> dan <i>maximum</i>) dan <i>error bar</i> yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-GA untuk material 2	73
Gambar 4.12. Plot nilai <i>MSE</i> dan <i>error bar</i> yang menunjukkan <i>confidence interval</i> dengan $\alpha = 0.05$, dari akurasi MLP-GA untuk material 2, dengan training set 1 dan 2	74
Gambar 4.13. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (<i>average</i>) dan minimum) untuk tiap-tiap <i>stress ratio</i> (<i>R</i>) dari MLP-GA dengan jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 200	75
Gambar 4.14. Plot nilai <i>MSE</i> testing terhadap jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 200 .	76
Gambar 4.15. Plot akurasi dalam R^2 dari model no. 6 dengan jumlah hidden nodes 25 hingga 30.	77
Gambar 4.16. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 1, dengan training Set 1, iterasi maksimum 200 dan jumlah hidden nodes = 20	78

Gambar 4.17. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 1, dengan training Set 2, iterasi maksimum 200 dan jumlah hidden nodes = 7	80
Gambar 4.18. Plot nilai <i>MSE</i> (<i>average</i> , <i>minimum</i> dan <i>maximum</i>) dan <i>error bar</i> yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-DE untuk material 1	81
Gambar 4.19. Plot nilai <i>MSE</i> dan <i>error bar</i> yang menunjukkan <i>confidence interval</i> dengan $\alpha = 0.05$, dari akurasi MLP-DE untuk material 1, dengan training set 1	81
Gambar 4.20. Nilai akurasi prediksi dalam R^2 (<i>maximum</i> , rata-rata (<i>average</i>) dan <i>minimum</i>) untuk tiap-tiap <i>stress ratio</i> (<i>R</i>) dari MLP-DE dengan jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200	82
Gambar 4.21. Plot nilai <i>MSE</i> testing terhadap jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200.....	84
Gambar 4.22. Plot akurasi dalam R^2 dari model no. 3 dengan jumlah hidden nodes 25 hingga 30.	85
Gambar 4.23. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 2, dengan training Set 2, iterasi maksimum 50 dan jumlah hidden nodes = 21	87
Gambar 4.24. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 2, dengan training Set 3, iterasi maksimum 200 dan jumlah hidden nodes = 6	90
Gambar 4.25. Plot nilai <i>MSE</i> (<i>average</i> , <i>minimum</i> dan <i>maximum</i>) dan <i>error bar</i> yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-DE untuk material 2	90
Gambar 4.26. Plot nilai <i>MSE</i> dan <i>error bar</i> yang menunjukkan <i>confidence interval</i> dengan $\alpha = 0.05$, dari akurasi MLP-DE untuk material 2, dengan training set 1 dan 2.	91
Gambar 4.27. Nilai akurasi prediksi dalam R^2 (<i>maximum</i> , rata-rata (<i>average</i>) dan <i>minimum</i>) untuk tiap-tiap <i>stress ratio</i> (<i>R</i>) dari MLP-DE dengan jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50	92
Gambar 4.28. Plot nilai <i>MSE</i> testing terhadap jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50.....	93
Gambar 4.29. Plot nilai <i>MSE</i> testing terhadap jumlah <i>hidden nodes</i> 6 hingga 21 untuk material 2, dengan training set 2 dan iterasi maksimum 50.....	94
Gambar 4.30. Plot akurasi dalam R^2 dari model no. 4 dengan jumlah hidden nodes 14 hingga 21.	95
Gambar 4.31. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 1, dengan training Set 1, iterasi maksimum 200 dan jumlah hidden nodes = 23.	96

Gambar 4.32. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 1, dengan training Set 2, iterasi maksimum 200 dan jumlah hidden nodes = 9	98
Gambar 4.33. Plot nilai <i>MSE (average, minimum dan maximum)</i> dan <i>error bar</i> yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-PSO untuk material 1	99
Gambar 4.34. Plot nilai <i>MSE</i> dan <i>confidence interval</i> dengan $\alpha = 0.05$, dari akurasi MLP-PSO untuk material 1, dengan training set 1	99
Gambar 4.35. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (<i>average</i>) dan minimum) untuk tiap-tiap <i>stress ratio (R)</i> dari MLP-PSO dengan jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200	100
Gambar 4.36. Plot nilai <i>MSE</i> testing terhadap jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200	101
Gambar 4.37. Plot akurasi dalam R^2 dari dari model no. 3 dengan jumlah hidden nodes 25 hingga 30	102
Gambar 4.38. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 2, dengan training Set 2, iterasi maksimum 200 dan jumlah hidden nodes = 12.	105
Gambar 4.39. <i>S-N curve</i> dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 2, dengan training Set 3, iterasi maksimum 200 dan jumlah hidden nodes = 26	107
Gambar 4.40. Plot nilai <i>MSE (average, minimum dan maximum)</i> dan <i>error bar</i> yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-PSO untuk material 2	108
Gambar 4.41. Plot nilai <i>MSE</i> dan dan <i>error bar</i> yang menunjukkan <i>confidence interval</i> dengan $\alpha = 0.05$, dari akurasi MLP-PSO untuk material 2, dengan training set 1 dan 2	108
Gambar 4.42. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (<i>average</i>) dan minimum) untuk tiap-tiap <i>stress ratio (R)</i> dari MLP-PSO dengan jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50	109
Gambar 4.43. Plot nilai <i>MSE</i> testing terhadap jumlah <i>hidden nodes</i> 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50	110
Gambar 4.44. Plot akurasi dalam R^2 dari dari model no. 4 dengan jumlah hidden nodes 25 hingga 30	112
Gambar 4.45. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -2$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	113
Gambar 4.46. Plot akurasi rata-rata dari model NN terhadap jumlah <i>hidden nodes</i> .	116
Gambar 4.47. Tabel ANOVA hasil pengujian untuk material 1 dengan <i>MSE</i> pada tiap percobaan sebagi respon (MLP-GA).	118

Gambar 4.48. Plot pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> dari pengujian ANOVA untuk material 1 (MLP-GA)	119
Gambar 4.49. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai <i>MSE</i> untuk material 1 (MLP-GA).....	120
Gambar 4.50. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai <i>MSE</i> untuk material 1 (MLP-GA).....	121
Gambar 4.51. Plot interaksi pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> untuk material 1 (MLP-GA).....	122
Gambar 4.52. Tabel ANOVA hasil pengujian untuk material 2 dengan <i>MSE</i> pada tiap percobaan sebagai respon (MLP-GA).	123
Gambar 4.53. Plot pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> dari pengujian ANOVA untuk material 2 (MLP-GA)	124
Gambar 4.54. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai <i>MSE</i> untuk material 2 (MLP-GA).....	125
Gambar 4.55. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai <i>MSE</i> untuk material 2 (MLP-GA).....	126
Gambar 4.56. Plot interaksi pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> untuk material 2 (MLP-GA).....	128
Gambar 4.57. Tabel ANOVA hasil pengujian untuk material 1 dengan <i>MSE</i> pada tiap percobaan sebagai respon (MLP-DE).	128
Gambar 4.58. Plot pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> dari pengujian ANOVA untuk material 1 (MLP-DE)	129
Gambar 4.59. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai <i>MSE</i> untuk material 1 (MLP-DE)	130
Gambar 4.60. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai <i>MSE</i> untuk material 1 (MLP-DE)	131
Gambar 4.61. Plot interaksi pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> untuk material 1 (MLP-DE)	132
Gambar 4.62. Plot perbedaan <i>MSE</i> rata-rata dari interaksi pengaruh faktor iterasi maksimum dan <i>training set</i> untuk material 1 (MLP-DE).....	133
Gambar 4.63. Tabel ANOVA hasil pengujian untuk material 2 dengan <i>MSE</i> pada tiap percobaan sebagai respon (MLP-DE)	133
Gambar 4.64. Plot pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> dari pengujian ANOVA untuk material 2 (MLPDE)	134
Gambar 4.65. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai <i>MSE</i> untuk material 2 (MLPDE)	135
Gambar 4.66. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai <i>MSE</i> untuk material 2 (MLP-DE)	136

Gambar 4.67. Plot interaksi pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> untuk material 2 (MLP-DE)	138
Gambar 4.68. Plot perbedaan <i>MSE</i> rata-rata dari interaksi pengaruh faktor iterasi maksimum dan <i>training set</i> untuk material 2 (MLP-DE)	138
Gambar 4.69. Tabel ANOVA hasil pengujian untuk material 1 dengan <i>MSE</i> pada tiap percobaan sebagai respon (MLP-PSO)	139
Gambar 4.70. Plot pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> dari pengujian ANOVA untuk material 1 (MLP-PSO)	140
Gambar 4.71. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai <i>MSE</i> untuk material 1 (MLP-PSO)	141
Gambar 4.72. Plot perbandingan antara pengaruh <i>training set</i> 1, 2 dan 3 terhadap nilai <i>MSE</i> untuk material 1 (MLP-PSO)	142
Gambar 4.73. Plot interaksi pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> untuk material 1 (MLP-PSO)	143
Gambar 4.74. Plot perbedaan <i>MSE</i> rata-rata dari interaksi pengaruh faktor iterasi maksimum dan <i>training set</i> untuk material 1 (MLP-PSO).....	144
Gambar 4.75. Tabel ANOVA hasil pengujian untuk material 2 dengan <i>MSE</i> pada tiap percobaan sebagai respon (MLP-PSO)	144
Gambar 4.76. Plot pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> dari pengujian ANOVA untuk material 2 (MLP-PSO)	145
Gambar 4.77. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai <i>MSE</i> untuk material 2 (MLP-PSO)	146
Gambar 4.78. Plot perbandingan antara pengaruh <i>training set</i> 1, 2 dan 3 terhadap nilai <i>MSE</i> untuk material 2 (MLP-PSO)	147
Gambar 4.79. Plot interaksi pengaruh faktor iterasi maksimum, <i>training set</i> dan <i>net size</i> (jumlah <i>hidden nodes</i>) terhadap nilai <i>MSE</i> untuk material 2 (MLP-PSO)	149
Gambar 4.80. Plot perbedaan <i>MSE</i> rata-rata dari interaksi pengaruh faktor iterasi maksimum dan <i>training set</i> untuk material 2 (MLP-PSO)	149
Gambar 4.81. Tabel hasil <i>Tukey simultaneous tests</i> untuk menguji perbedaan <i>MSE</i> rata-rata antara metode optimasi GA, DE dan PSO untuk material 1.	150
Gambar 4.82. Plot hasil <i>Tukey simultaneous tests</i> untuk menguji perbedaan <i>MSE</i> rata-rata antara metode optimasi GA, DE dan PSO untuk material 1.	151
Gambar 4.83. Tabel hasil <i>Tukey simultaneous tests</i> untuk menguji perbedaan <i>MSE</i> rata-rata antara metode optimasi GA, DE dan PSO untuk material 2.	151
Gambar 4.84. Plot hasil <i>Tukey simultaneous tests</i> untuk menguji perbedaan <i>MSE</i> rata-rata antara metode optimasi GA, DE dan PSO untuk material 2.	152
Gambar L1.1. Susunan lamina penyusun laminat	167
Gambar L1.2. Susunan di dalam <i>fiber-reinforced composites</i>	168

Gambar L1.3. Aturan sudut arah orientasi serat	169
Gambar L1.4. (a) <i>Unidirectional laminate</i> dengan arah serat seragam 0° , dikodekan dengan (0/0/0). (b) <i>Unidirectional laminate</i> dengan arah serat seragam 45° , dikodekan dengan [45/45/45]	169
Gambar L1.5. <i>Angle-ply laminate</i> dengan arah serat $+45^\circ$, -45° , $+45^\circ$, -45° , dikodekan dengan $[\pm 45_2]$	169
Gambar L1.6. <i>Cross-ply laminate</i> dengan arah serat 90° , 0° , 90° , 0° , dikodekan dengan [0/90/0/90]	170
Gambar L1.7. <i>Symmetric laminate</i> dengan arah serat 0° , $+45^\circ$, -45° , 90° , 90° , -45° , $+45^\circ$, 0° ; dikodekan dengan $[0/\pm 45/90]_s$. <i>Subscript S</i> adalah menunjukkak bahwa laminat simetri terhadap referensi C/L laminat .	170
Gambar L1.8. Model paralel dan model seri untuk menggambarkan kekakuan komposit pada arah yang berbeda	173
Gambar L1.9. Longitudinal tensile loading pada unidirectional continuous fiber lamina, dimana σ_{fu} adalah ultimate tensile strength serat, σ_{Ltu} adalah ultimate tensile strength lamina atau komposit, dan σ_{mu} adalah ultimate tensile strength dari matrix	174
Gambar L1.10. <i>Longitudinal tensile strength</i> yang nilainya bervariasi dengan <i>fiber volume fraction</i> pada <i>unidirectional continuous fiber composite</i> dengan <i>matrix failure strain</i> lebih besar dari <i>fiber failure strain</i>	177
Gambar L2.1. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = 0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%	181
Gambar L2.2. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%	181
Gambar L2.3. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -1$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	182
Gambar L2.4. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -2$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	182
Gambar L2.5. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = -0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	183
Gambar L2.6. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = -1$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	183

Gambar L2.7. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = -2$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	184
Gambar L2.8. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = 10$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	184
Gambar L2.9. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = -0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	185
Gambar L2.10. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = -1$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	185
Gambar L2.11. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = -2$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	186
Gambar L2.12. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = 10$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	186
Gambar L2.13. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	187
Gambar L2.14. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.7$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	187
Gambar L2.15. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.8$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	188
Gambar L2.16. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.9$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	188
Gambar L2.17. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = -0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	189
Gambar L2.18. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = -2$. Kurva disusun dari	

	data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	189
Gambar L2.19.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 10$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	190
Gambar L2.20.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	190
Gambar L2.21.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.7$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	191
Gambar L2.22.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.8$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	191
Gambar L2.23.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.9$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	192
Gambar L2.24.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = -0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	192
Gambar L2.25.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = -2$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	193
Gambar L2.26.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 10$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	193
Gambar L2.27.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	194
Gambar L2.28.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.7$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	194
Gambar L2.29.	Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.8$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	195

Gambar L2.30. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.9$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	195
Gambar L2.31. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = -0.5$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	196
Gambar L2.32. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = -2$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	196
Gambar L2.33. Kurva <i>P-S-N</i> hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 10$. Kurva disusun dari data (<i>scatter</i>) yang terdistribusi normal dengan tingkat kepercayaan 95%.	197

DAFTAR TABEL

Tabel 2.1. Penelitian Tentang Penggunaan Neural Network Dalam Prediksi Umur Kelelahan Komposit	7
Tabel 3.1. Data Material Komposit E-glass/Epoxy MD-QQ1-EP2-S	47
Tabel 3.2. Data Material Komposit E-glass/polyester MD-DD16-UP2	47
Tabel 3.3. Tabel Rencana Penelitian Untuk Material 1	51
Tabel 3.4. Tabel Rencana Penelitian Untuk Material 2	51
Tabel 4.1. Parameter Yang Digunakan Pada Pemodelan NN	57
Tabel 4.2. Parameter GA Yang Digunakan Pada Pemodelan NN	57
Tabel 4.3. Parameter DE Yang Digunakan Pada Pemodelan NN	57
Tabel 4.4. Parameter PSO Yang Digunakan Pada Pemodelan NN	58
Tabel 4.5. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.4 Dan 4.5 Dan Nilai MSE (Average, Minimum dan Maximum) Pada Masing-masing Model (MLP-GA)	65
Tabel 4.6. Akurasi Prediksi Model MLP-GA Dengan Nilai MSE dan R ² Untuk Material 1 Dengan Training Set 3, Iterasi Maksimum 200 Dan Jumlah Hidden Nodes 6 Hingga 30 (model no. 9)	66
Tabel 4.7. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.11 Dan 4.12 Dan Nilai MSE (Average, Minimum dan Maximum) Pada Masing-masing Model	74
Tabel 4.8. Akurasi Prediksi Model MLP-GA Dengan Nilai <i>MSE</i> dan R ² Untuk Material 2 Dengan Training Set 2, Iterasi Maksimum 200 Dan Jumlah Hidden Nodes 6 Hingga 30 (model no. 6)	75
Tabel 4.9. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.18 dan 4.19 Dan Nilai <i>MSE</i> (Average, Minimum dan Maximum) Pada Masing-masing Model	82
Tabel 4.10. Akurasi Prediksi Model MLP-DE Dengan Nilai <i>MSE</i> dan R ² Untuk Material 1 Dengan Training Set 1, Iterasi Maksimum 200 Dan Jumlah <i>Hidden Nodes</i> 6 Hingga 30	83
Tabel 4.11. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.25 Dan 4.26 Dan Nilai <i>MSE</i> (Average, Minimum dan Maximum) Pada Masing-masing Model	91
Tabel 4.12. Akurasi Prediksi Model MLP-DE Dengan Nilai <i>MSE</i> dan R ² Untuk Material 2 Dengan Training Set 2, Iterasi Maksimum 50 Dan Jumlah Hidden Nodes 6 Hingga 30	92
Tabel 4.13. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.33 Dan 4.34 Dan Nilai <i>MSE</i> (Average, Minimum dan Maximum) Pada Masing-masing Model	100
Tabel 4.14. Akurasi Prediksi Model MLP-PSO Dengan Nilai <i>MSE</i> dan R ² Untuk Material 1 Dengan Training Set 1, Iterasi Maksimum 200 Dan Jumlah <i>Hidden Nodes</i> 6 Hingga 30	101
Tabel 4.15. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.40 dan 4.41 Dan Nilai <i>MSE</i> (Average, Minimum dan Maximum) Pada Masing-masing Model	109

Tabel 4.16.	Akurasi Prediksi Model MLP-PSO Dengan Nilai <i>MSE</i> dan R^2 Untuk Material 2 Dengan Training Set 2, Iterasi Maksimum 50 Dan Jumlah Hidden Nodes 6 Hingga 30	110
Tabel 4.17.	Akurasi Prediksi Model MLP-GA Untuk Material 1.....	113
Tabel 4.18.	Akurasi Prediksi Model MLP-DE Untuk Material 1.....	114
Tabel 4.19.	Akurasi Prediksi Model MLP-PSO Untuk Material 1.....	114
Tabel 4.20.	Akurasi Prediksi Model MLP-GA Untuk Material 2.....	114
Tabel 4.21.	Akurasi Prediksi Model MLP-DE Untuk Material 2.....	115
Tabel 4.22.	Akurasi Prediksi Model MLP-PSO Untuk Material 2.....	115
Tabel 4.23.	Uji Hipotesa Untuk Analisa Sensitifitas.....	117
Tabel 4.24.	Perbandingan Akurasi NN-Metaheuristik Dan NN- <i>Gradient-Based</i>	153
Tabel 4.25.	Perbedaan MSE Antara Model NN-Metaheuristik Dan NN- <i>Gradient-Based</i>	154
Tabel 4.26.	Perhitungan Statistik Perbedaan Nilai MSE Antara NN-Metaheuristik Dan NN- <i>Gradient-Based</i>	154
Tabel L1.1.	Material Resin Yang Telah Digunakan Untuk Penelitian Komposit Yang Sudah Dikembangkan Oleh SNL/MSU/DOE.....	163
Tabel L1.2.	Material Serat Yang Telah Digunakan Untuk Penelitian Komposit Oleh SNL/MSU/DOE.....	164
Tabel L1.3.	<i>Properties</i> dari Beberapa <i>Reinforcing fibers</i> Jenis <i>Glass fibers</i> dan <i>Carbon fibers</i>	166
Tabel L1.4.	Contoh Nilai <i>Critical v_f</i> Dari Serat <i>E-glass</i> Dan Serat <i>Carbon</i> Dengan <i>Matrix Epoxy</i>	177
Tabel L1.5.	Contoh Efek <i>Transverse Loading</i> Pada <i>Unidirectional Composite</i>	178

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Material komposit (*fibre reinforced polymer*) banyak digunakan dalam komponen vital pada suatu struktur, misalnya pada bilah turbin angin, bilah helikopter, propeler kapal terbang dan kapal laut, hal tersebut dikarenakan material tersebut memiliki keunggulan pada properti *stiffness*, *stiffness-to-density ratio*, dan *fracture toughness* (Brøndsted dkk. 2005). Komponen tersebut dirancang untuk mampu beroperasi dalam waktu yang lama tanpa mengalami kegagalan, sebagai contoh adalah pada turbin angin untuk beroperasi secara kontinyu selama 20 tahun untuk konstruksi di *onshore* dan 25 tahun untuk konstruksi di *offshore* (Morthorst, 2009). Penyebab utama kegagalan komposit selama *service loading* adalah kelelahan (Movaghghar, 2012), sehingga asesmen terhadap kegagalan karena kelelahan merupakan salah satu bagian dari perencanaan dalam fase desain yang wajib dilakukan.

Kelelahan merupakan masalah yang paling rumit pada konstruksi dengan material komposit karena komposisi dan kompleksitas karakteristik dari interaksi fiber-matriks, dan mekanisme kegagalannya masih belum begitu dipahami. Pengembangan model harus diuji dengan pengujian kelelahan yang membutuhkan data yang sangat banyak, sehingga pemodelan tersebut membutuhkan biaya yang sangat besar dan waktu yang lama. Metode alternatif sangat diperlukan dengan tujuan untuk menekan biaya pengujian dan waktu pengerjaan tetapi tetap dengan akurasi yang bisa diterima.

Para peneliti di bidang kelelahan telah mengembangkan *artificial neural network* (NN) untuk memprediksi kelelahan material komposit. Metode *gradient-based search* sudah banyak digunakan sebagai algoritma optimasi bobot dan bias pada NN untuk aplikasi prediksi umur kelelahan komposit berbasis polimer, diantaranya adalah Al-Assaf dkk. (2001), El-Kady dkk. (2002), Lee dkk. (2003), Freire Jr. dkk. (2005), Vassilopoulos dkk. (2007), Bezazi dkk. (2007), Freire dkk., (2007, 2009), Hidayat dkk. (2009) dan Xiang dkk. (2014).

Akhir-akhir ini metode optimasi yang lebih baru yaitu metaheuristik telah banyak digunakan untuk optimasi NN, namun aplikasinya masih di luar bidang prediksi umur kelelahan komposit, sebagai contoh adalah Piotrowski (2014), Lazzus (2016), Jenab dkk. (2016), Vakili dkk. (2017) dan Manshad dkk. (2015).

Dalam penelitian ini, digunakan arsitektur *multilayer perceptrons* (MLP) dengan menggunakan tiga metode algoritma metaheuristik, yaitu *genetic algorithm* (GA), *particle swarm optimization* (PSO) dan *differential evolution* (DE), untuk membangun aproksimasi fungsi untuk memprediksi umur kelelahan material komposit (*fibre reinforced polymer*) yang mengalami *multivariable amplitude loading*. GA, PSO dan DE merupakan metode algoritma yang terinspirasi oleh kejadian di alam.

1.2 Perumusan Masalah

Permasalahan yang dibahas dan dirumuskan dalam penelitian ini adalah:

1. Bagaimana model NN yang optimal dan efisien dengan teknik metaheuristik untuk prediksi umur kelelahan material komposit?
2. Bagaimana pengaruh parameter NN dan algoritma metaheuristik terhadap kinerja model NN yang dikembangkan?

1.3 Asumsi

Asumsi dalam penelitian ini adalah:

1. Generasi populasi awal dari bobot cukup random.
2. Data dianggap mengikuti distribusi normal.

1.4 Lingkup Penelitian

Lingkup dalam penelitian ini adalah:

1. Penelitian dilakukan pada komposit berbasis polimer.
2. Teknik metaheuristik digunakan hanya untuk mengoptimalkan bobot, dan bias tidak untuk mengoptimalkan arsitektur NN.

1.5 Tujuan Penelitian

Penelitian ini dilakukan dengan beberapa tujuan yaitu:

1. Membangun model NN yang optimal dan efisien dengan teknik metaheuristik untuk prediksi umur kelelahan material komposit.

2. Menganalisa pengaruh parameter NN dan metode algoritma metaheuristik terhadap kinerja model.

1.6 Manfaat Penelitian

Manfaat dari penelitian ini adalah diketahuinya efektifitas dari penggunaan metode optimasi metaheuristik sebagai algoritma di dalam proses training NN untuk memprediksi umur kelelahan komposit (*fibre reinforced polymer*) dengan menggunakan fatigue data set untuk training dengan jumlah data yang terbatas. Melalui analisa sensitivitas akan diketahui pengaruh dari banyaknya neuron pada hidden node sehingga bisa diketahui berapa jumlah neuron yang dibutuhkan sehingga dihasilkan aproksimasi fungsi yang memiliki kemampuan untuk memprediksi umur kelelahan material komposit.

Dengan kemampuannya untuk memprediksi umur kelelahan sehingga dapat dimanfaatkan untuk menghasilkan data kelelahan dengan lebih cepat dibandingkan dengan eksperimen yang menggunakan sample yang banyak dan membutuhkan waktu pengerjaan yang lama, dengan demikian biaya dan waktu eksperimen untuk pengujian kelelahan bisa ditekan.

(Halaman ini sengaja dikosongkan)

BAB 2

KAJIAN PUSTAKA DAN DASAR TEORI

2.1 Penelitian Prediksi Umur Kelelahan Komposit Dengan *Artificial Neural Network* (NN)

Al-Assaf dkk. (2001), dan El-Kadi dkk. (2002), melakukan analisa umur kelelahan dari *glass fiber/epoxy* lamina menggunakan beberapa paradigma NN yang berbeda, yaitu *feed forward* / MLP dengan *back propagation training*, *modular neural network* (MN), *radial basis function* (RBF) dan *principal component analysis* (PCA), dan dibandingkan dengan data eksperimen. Beberapa spesimen dengan lima sudut orientasi fiber yang berbeda yaitu 0°, 19°, 45°, 71° dan 90° diuji dengan kondisi stress ratio (R) -1, 0, dan 0.5. Sembilanpuluh dua data digunakan sebagai data set untuk NN. Mereka menemukan bahwa NN dapat ditraining untuk memodelkan perilaku komposit yang non-linier yang menerima pembebanan cyclic, dan hasil prediksi menunjukkan kinerja yang tidak jauh berbeda dengan metode prediksi umur kelelahan material komposit yang lain.

Freire Jr. dkk. (2005), menggunakan NN *feed forward* / MLP dengan *back propagation training* untuk memprediksi umur kelelahan material *fiberglass/polyester* dengan *lay-up* $[90/0/\pm 45/0]_S$ dalam bentuk *constant life diagram* (CLD). Empat training *data sets* (masing-masing data dari 3R, 4R, 5R dan 6R) yang didapatkan dari dua belas nilai R . Dari penelitian tersebut didapatkan bahwa NN cukup menjanjikan untuk digunakan untuk membangun CLD. Hanya dengan tiga kurva $S-N$ yang mampu digunakan untuk membangun sembilan kurva $S-N$ baru di dalam CLD. Hasil prediksi terbaik didapatkan dengan training menggunakan 6R.

Vassilopoulos dkk. 2007, menggunakan NN untuk memprediksi umur kelelahan komposit dalam bentuk *constant life diagram* (CLD) dari *E-glass fiber/polyester* dengan *stacking sequence* $[0/(\pm 45)_2/0]_T$ dan *fabric/orthopolyester* dengan *stacking sequence* $[90/0/\pm 45/0]_S$. *Feed forward* / MLP dengan *back propagation* dengan 40 - 50% dari jumlah data digunakan untuk training.

Bezazi dkk., 2007, menggunakan MLP dengan *back propagation training*

untuk memprediksi umur kelelahan material dengan struktur yang berlapis (*cross-ply laminates skins and PVC foam cores*). *Cost function* dimodifikasi dengan *maximum likelihood error* dan aturan *bayesian*.

Freire Jr. dkk., (2007, 2009), dengan menggunakan *modular networks* (MN) mampu menghasilkan hasil yang lebih bagus dibandingkan dengan *feed-forward* (FF) *neural network*. Namun, untuk menghasilkan hasil yang lebih baik harus menggunakan data set training dengan jumlah yang lebih banyak.

Hidayat dkk., 2009, telah menggunakan jumlah data kelelahan yang terbatas dengan menggunakan NN MLP dengan *back propagation training* dan *Bayesian regulation* untuk memodelkan prediksi umur kelelahan material komposit material *E-glass/epoxy* ($[\pm 45/0_4/\pm 45]$) dan *E-glass/polyester* ($[90/0/\pm 45/0]_s$) dengan pembebanan kelelahan pada beberapa kondisi *stress ratio*. Telah didapatkan bahwa meskipun hanya dengan menggunakan dua data *stress ratio* untuk training, model NN tersebut memiliki kemampuan untuk menjeneralisasi dengan baik dan hasilnya memiliki akurasi yang bagus meskipun pada rentang *stress ratio* yang lebar. Tingkat keandalan dan akurasi dari prediksi tersebut dinilai dengan angka *MSE* yang kecil.

Xiang dkk. (2014), menggunakan *multilayer perceptrons* dengan *back propagation training* untuk memprediksi umur kelelahan komposit *natural fiber*. Dalam penelitian tersebut, prediksi umur kelelahan menunjukkan akurasi yang tinggi, namun demikian hasil tersebut dicapai dengan jumlah data training yang besar yaitu lebih dari 88% dari total *data set*.

Secara singkat beberapa penelitian prediksi umur kelelahan komposit ditunjukkan pada Tabel 2.1.

Tabel 2.1. Penelitian Tentang Penggunaan *Neural Network* Dalam Prediksi Umur Kelelahan Komposit


Peneliti	Metode
Al-Assaf dkk. (2001) El-Kady dkk. (2002)	<i>Feed forward / multilayer perceptrons</i> dengan <i>back propagation training</i> , <i>modular neural network</i> (MN), <i>radial basis function</i> (RBF) dan <i>principal component analysis</i> (PCA)
Freire Jr. dkk. (2005)	<i>Feed forward / MLP</i> dengan <i>back propagation training</i>
Vassilopoulos dkk. (2007)	<i>Feed forward / MLP</i> dengan <i>back propagation</i>
Bezazi dkk. (2007)	MLP dengan <i>back propagation training</i> . <i>Cost function</i> dimodifikasi dengan <i>maximum likelihood error</i> dan aturan <i>bayesian</i> .
Freire dkk., (2007, 2009)	<i>Feedforward neural network</i> (FNN) dengan algoritma <i>training back propagation</i> , <i>Modular networks</i> (MN)
Hidayat dkk. (2009)	MLP dengan <i>back propagation training</i> dan <i>Bayesian regulation</i>
Xiang dkk. (2014)	MLP dengan <i>back propagation training</i>

Pada akhir-akhir beberapa peneliti menggunakan algoritma metaheuristik untuk training NN, namun demikian penggunaannya masih di luar bidang prediksi umur kelelahan komposit. Sebagai contoh adalah Piotrowski (2014) menggunakan MLP dengan *differential evolution* sebagai algoritma training dalam bidang *hydrometeorology*. Lazzus (2016) menggunakan MLP dengan genetika algoritma sebagai algoritma training untuk memprediksi nilai konduktivitas termal dari 41 jenis *ionic liquids* pada temperatur dan tekanan yang bervariasi. Jenab dkk. (2016) menggunakan MLP dengan genetika algoritma sebagai algoritma training untuk memprediksi *rate-dependent tensile flow behaviour* dari material pelat aluminium alloy AA5182-O. Vakili dkk. (2017) menggunakan MLP dengan genetika algoritma sebagai algoritma training untuk memprediksi viskositas *graphene nanoplatelets nanofluid*. Manshad dkk. (2015) menggunakan MLP dengan *particle swarm optimization* sebagai algoritma training untuk memprediksi *dew point pressure* pada *gas condensate reservoirs*.

2.2 Kelelahan Material Komposit

Sebuah beban kelelahan pada umumnya ditunjukkan dengan pembebanan yang cyclic, berbentuk gelombang, dan biasanya sinusoidal. Karakteristik dari

bentuk gelombang beban cyclic diambarkan dalam Gambar 2.1, dengan notasi yang umum digunakan yaitu S dan N . S bisa menunjukkan *stress*, beban (per unit lebar atau ketebalan), *strain* atau *displacement*. Umumnya S menunjukkan *stress* pada material yang homogen, sedangkan untuk komposit umumnya menunjukkan *strain*. Untuk notasi N , digunakan untuk menunjukkan jumlah siklus hingga terjadi kegagalan, kadang juga dipakai untuk menunjukkan setengah dari jumlah siklus hingga terjadi kegagalan, jumlah urutan beban hingga terjadinya kegagalan, atau jumlah siklus dari penurunan nilai kekakuan.



Gambar 2.1. Terminologi kelelahan secara umum (Nijssen, 2007).

Hasil dari data eksperimen pengujian kelelahan umumnya ditunjukkan dalam diagram S - N , yang menunjukkan nilai S vs. N , sebagai contoh ditunjukkan pada Gambar 2.1. Umumnya properties kelelahan bisa dilihat dari kemiringan pada diagram S - N , jika kemiringan lebih landai menunjukkan *properties* kelelahan yang lebih baik dibandingkan dengan yang lebih tajam.

2.3 Kelelahan *Constant Amplitude Loading*

Beban kelelahan yang dialami oleh struktur di lapangan bervariasi dalam hal *stress amplitude* dan *mean stress*. Umur kelelahan dengan beban cyclic yang bervariasi selalu diprediksi dengan perilaku kelelahan pada pembebanan dengan *constant amplitude*, sehingga perlu diketahui metode untuk mengetahui umur kelelahan pada *variable amplitude loading* dengan menggunakan data *constant amplitude loading*.

Constant amplitude loading diilustrasikan seperti pada Gambar 2.2, dimana:

σ_{\max} = tegangan *cyclic* maksimum

σ_{\min} = tegangan *cyclic* minimum


σ_m = tegangan *cyclic* rata-rata (*mean stress*)

σ_a = amplitudo tegangan *cyclic* (*stress amplitude*)

$\Delta\sigma$ = rentang tegangan *cyclic* (*stress range*)


T = periode gelombang

f = frekwensi gelombang



Gambar 2.2. Terminologi dasar kelelahan.

Pembebanan pada uji kelelahan diklasifikasikan sebagai *tension - tension* (T-T), *tension - compression* (T-C) dan *compression - compression* (C-C), seperti yang diperlihatkan pada Gambar 2.3.




Gambar 2.3. Klasifikasi pembebanan pada uji kelelahan.

2.4 Kelelahan *Variable Amplitude Loading*


Pola beban *cyclic* pada konstruksi yang nyata dilapangan berbentuk tidak

beraturan, contohnya adalah seperti yang diperlihatkan pada Gambar 2.4.



Gambar 2.4. Pola pembebanan siklik yang tidak beraturan.

Untuk tujuan analisa, pola pembebanan yang tidak beraturan harus dikonversikan menjadi pola yang bisa dianalisa dengan metode *constant amplitude*, contoh konversi tersebut seperti yang ditunjukkan pada Gambar 2.5. Metode yang paling umum digunakan untuk konversi tersebut adalah *counting method*.



Gambar 2.5. Skematik *counting method*.

2.5 Constant life diagram (CLD)


CLD sangat berguna sebagai alat untuk penilaian umur kelelahan dalam kondisi pembebanan kelelahan dengan amplitudo beban yang bervariasi. Di dalam CLD, semua titik di sepanjang garis radial merupakan titik-titik pada kurva S-N untuk *stress ratio* (R) yang tertentu, dan semua titik dengan umur kelelahan yang sama dihubungkan dengan garis pada bidang amplitudo tegangan (σ_a) dan tegangan rata-rata (σ_m). CLD secara skematik diilustrasikan pada Gambar 2.6. Hubungan antara σ_a dan σ_m dirumuskan seperti persamaan:

$$\sigma_a = \left(\frac{1-R}{1+R} \right) \sigma_m \quad (2.1)$$


Kecuali $R = -1$, dimana $\sigma_m = 0$ dan $\sigma_a = \sigma_{\max}$

$$\text{Stress ratio } (R) = \frac{\sigma_{\min}}{\sigma_{\max}} \quad (2.2)$$

Struktur yang mengalami pembebanan siklik di bawah umur kelelahan tertentu akan memiliki umur kelelahan yang sama, tidak tergantung pada kondisi pembebanan, sebagai contoh, dengan menggunakan CLD pada Gambar 2.6, jika pembebanan berada pada daerah di bawah garis 10^4 cycles, struktur akan memiliki umur yang sama meskipun mengalami pembebanan siklik dengan *stress ratio* (R) yang ataupun klasifikasi pembebanan (T-T, T-C dan C-C) yang berbeda-beda, secara skematik diilustrasikan pada Gambar 2.7.



Gambar 2.6. Contoh CLD (Freire, 2005)



Gambar 2.7. Ilustrasi pembebanan dengan *variable amplitude* dan *variable stress ratio* (R)


2.6 Mekanisme kelelahan material komposit

2.6.1 Degradasi kekuatan dan kekakuan


Kegagalan akibat kelelahan merupakan akibat dari menurunnya kekuatan dan kekakuan komposit setelah mengalami pembebanan yang berfluktuasi dan berulang-ulang. Fiber putus, retak pada *matrix*, *fiber-matrix debonding*, dan *delamination* terjadi sebagai respon dari pembebanan berfluktuasi dan berulang-ulang. (Anderson, 2005)

Retakan dalam ukuran yang sangat kecil tersebar merata di dalam matriks polimer atau pada interface antara serat dan matriks. Dengan semakin panjang ukurang retakan maka beberapa retakan akan bertemu. Semakin lama ukuran retak akan semakin tumbuh membesar sehingga kekuatan dan kekakuan material semakin lama semakin menurun atau terjadi *cumulative damage*. Ketika luas penampang material sudah tidak cukup kuat menyangga beban maka terjadi kegagalan karena kelelahan. (Andersen dkk., 1996)


Gambar 2.8 menunjukkan ilustrasi dari beberapa contoh kerusakan yang terjadi pada material komposit. Gambar 2.9 dan 2.10 menunjukkan efek tegangan siklis terhadap *residual stress* dan kekakuan dari komposit graphite/epoxy laminat, dimana kerusakan material melalui tiga *stage*. Dari grafik tersebut terlihat bahwa baik kekuatan maupun kekakuan dari komposit turun secara drastis setelah mengalami beban pada siklus awal, kemudian turun dengan kemiringan yang landai, setelah mencapai umur sekitar 80%, material menunjukkan penurunan kekuatan dan kekakuan secara drastis.



Gambar 2.8. Beberapa contoh kerusakan yang terjadi pada fibre reinforced composite (ilustratif) (Anderson, 2005).



Gambar 2.9. *Residual strength* dari komposit graphite/epoxy laminat setelah mengalami kerusakan akibat kelelahan (Anderson, 2005).



Gambar 2.10. *Residual stiffness* dari komposit graphite/epoxy laminat setelah mengalami kerusakan akibat kelelahan (Anderson, 2005).

Tingkat keparahan dari kerusakan pada masing-masing *stage*, dan tingginya total penurunan kekakuan tergantung pada komposisi laminat dan material properties, serta tipe pembebanan kelelahannya (Nijssen, 2007).


2.6.2 Kelelahan material polimer

Kelelahan material polimer dikendalikan oleh dua mekanisme: yaitu *chain scission* dan *hysteresis heating*.

Chain scission adalah mekanisme terputusnya ikatan antar atom. *Crack growth* secara *chain scission* terjadi pada material material yang *brittle*, yaitu material dengan *strain* atau *elongation* yang rendah, dimana *crack tip yielding* sangat terbatas atau sangat kecil, sehingga *crack* terjadi tanpa di dahului oleh *yielding* yang panjang. Beberapa ikatan putus pada setiap siklus, sehingga setelah sepanjang waktu tertentu, *crack* bisa diukur dengan beberapa alat pendeteksi cacat.

Material yang lebih tangguh atau lebih *ductile* menunjukkan mekanisme pemutusan ikatan yang berbeda, yaitu terjadinya *viscoelastic deformation* dan *yielding* pada *crack tip*. Gambar 2.11 menunjukkan ilustrasi perilaku *stress-strain* pada material *viscoelastic* dalam satu siklus *load-unload*. Tidak seperti pada

material yang elastis, misalnya metal, dimana jalur strain baik pada *loading* maupun *unloading* akan berada pada posisi yang sama sehingga terlihat *strain* energi bisa terpulihkan, pada material *viscoelastic* menunjukkan *hysteresis loop* pada kurva *stress-strain*; area di dalam *loop* menunjukkan energi yang masih berada pada material setelah beban dihilangkan. Ketika material *viscoelastic* mengalami siklus *loading-unloading* yang panjang, akan semakin banyak energi yang terserap atau tertinggal di material, dan sebagian energi tersebut dikonversikan menjadi panas, sehingga temperature di dalam material menjadi meningkat. Material *polymer* yang mengalami pembebanan yang *cyclic*, pada daerah sekitar *crack tip* akan terjadi kenaikan temperature hingga di atas *glass transition temperature* (T_g), yang mengakibatkan *local melting* dan *viscous flow*. *Crack growth* tergantung pada tingginya temperatur pada *crack tip*, yang dipengaruhi oleh frekuensi *loading-unloading* dan *rate* dari konduktifitas panas.



Gambar 2.11. Ilustrasi kurva *hysteresis* sebuah siklus *stress-strain* pada material *viscoelastic*. *Hysteresis* mengakibatkan terjadinya penyerapan energi yang kemudian dikonversikan menjadi panas (Anderson, 2005).

2.7 Karakteristik material komposit

Material komposit terdiri dari dua atau lebih material yang digabungkan untuk menghasilkan *properties* yang berbeda dari individual material penyusunnya. Komponen dari material komposit terdiri dari dua, yaitu *reinforcing fibres* dan *matrix*. *Reinforcing fibres* berperan untuk meningkatkan kekuatan (*strength*) dan kekakuan (*stiffness*). *Matrix* berperan untuk menahan dan melindungi *fibre* serta mendistribusikan beban.

Final properties dari sebuah komposit yang paling utama ditentukan oleh beberapa faktor, yaitu *properties* dari *fibres* dan *matrix*, persentase *fibres* atau *fibre volume fraction*, serta orientasi dan geometri dari *fibrous reinforcement*.

2.7.1 Matriks komposit

Komposit yang digunakan untuk bilah turbin angin umumnya menggunakan komposit dengan matriks polimer. Polimer yang digunakan pada umumnya menggunakan tipe *thermoset*, yaitu *polyester*, *vinyl ester* dan *epoxy*. Material *thermoset* dipilih karena faktor kemudahan dalam fabrikasi bilah turbin, meskipun juga mempunyai kekurangan yaitu waktu *curing* yang cukup lama, ketangguhan yang kurang baik, dan terjadinya reaksi eksotermal selama proses *curing*. Polymer tipe *thermoplastic* memiliki keunggulan dibandingkan *thermoset* yaitu ketangguhan yang lebih tinggi dan *recyclability*, tetapi memiliki kekurangan yaitu dalam proses fabrikasi harus dengan temperatur dan tekanan yang tinggi sehingga cukup menjadi kesulitan dalam proses fabrikasi. Selain dari yang disebutkan sebelumnya, kinerja kelelahan dari *thermoplastic* dilaporkan lebih buruk dari *thermoset-based laminates* (Gamstedt dkk., 1999). Nilai kekuatan tarik dan kekakuan tarik diantara *polyester*, *vinyl ester* dan *epoxy*, yang tertinggi adalah *epoxy*, yang kedua adalah *vinylester* dan yang terakhir adalah *polyester* (Aymerich, 2012)

2.7.2 Serat penguat


Serat penguat atau *Reinforcing fibres* yang umum digunakan pada bilah turbin angin umumnya adalah *glass fibres*, *carbon fibres* dan *aramid fibres*. *Carbon fibres* secara umum memiliki nilai kekuatan dan kekakuan yang paling tinggi, kemudian disusul oleh *aramid* dan *glass fibres*.

2.7.3 Sifat kelelahan komposit

Dibandingkan material lain, komposit menunjukkan kelebihan dalam hal ketahanan terhadap kelelahan, salah satu contohnya ditunjukkan secara skematik pada Gambar 2.12. Dari gambar tersebut memperlihatkan bahwa kemiringan dari material komposit menunjukkan paling landai dibandingkan material lain.

Salah satu karakter kelelahan dari komposit yang ditunjukkan oleh kurva

$S-N$ adalah tidak ditemukannya batas aman kelelahan, dan tidak ada batas pembebanan siklik sehingga umur kelelahan menjadi tidak terhingga. Karena tidak adanya batas aman pembebanan siklik, maka tiap siklus dianggap sebagai kerusakan struktur material, karena tingginya kekuatan pada awal siklik dan umumnya kurva $S-N$ yang landai sehingga umur kelelahan komposit menjadi sangat panjang.



Gambar 2.12. Properties kelelahan material yang digunakan dalam industri kapal terbang (Campbell, 2010).

Hal yang kurang menguntungkan dari material komposit salah satunya adalah *scatter* pada umur kelelahan yang lebih tinggi dari metal. Sumber dari *scatter* tersebut merupakan variabel yang *inherent*, yang berbeda dari satu kupon ke kupon yang lain, dan tidak tergantung pada *strain level*. Dari hasil pengujian statis diketahui bahwa umumnya nilai *scatter* berkisar 10% dari nilai rata-rata. Besarnya *scatter* dipengaruhi oleh beberapa parameter (yang independen), antara lain *properties* yang bervariasi di dalam *fibre* dan *matrix*, kondisi *manufacturing*, faktor kupon (geometri, ukuran dan *pre-treatment*), *level* dari *stress/strain* dan nilai *stress ratio*, dan *test set up* (Nijssen, 2007).

2.7.4 Anisotropi komposit

Material komposit bersifat anisotropic, artinya memiliki properties yang berbeda untuk orientasi beban yang berbeda, sebagai contoh adalah modulus elastisitas (E), dimana $E_{0^\circ} \neq E_{45^\circ} \neq E_{90^\circ}$. Seperti halnya dengan modulus elastisitas, properties lainnya juga tergantung pada orientasinya, seperti *ultimate strength*, *Poisson's ratio* dan koefisien ekspansi termal.

2.7.5 Pengaruh *fibre volume fraction* (arah pembebanan longitudinal)

Fraksi volum fiber atau *fibre volume fraction* (V_f) adalah nilai perbandingan antara volum fiber (v_f) terhadap volume composite (v_c), $V_f = v_f / v_c$. Kontribusi fiber dan matrix terhadap sifat mekanik komposit adalah proporsional dengan fraksi volume-nya, jika *fibre volume fraction* besar maka sifat komposit yang terbentuk juga bertendensi sifat fiber. Kurva tegangan-regangan komposit selalu berada diantara matrix dan fiber, serta bentuk kurvanya juga mengikuti pembentuknya, jika kurva pembentuknya adalah linier maka kurva komposit akan linier, dan jika kurva pembentuknya non linier maka kurva komposit akan non linier (Sulistijono, 2012).

Kekuatan komposit ditentukan oleh *fibre volume fraction*, tetapi besarnya tidak selalu berbanding lurus mulai fibre volume fraction nol hingga 100%. Secara umum, hubungan antara fibre volume fraction V_f terhadap kekuatan komposit ditunjukkan pada Gambar 2.13. Pada komposit *unidirectional*, keberadaan fiber akan menurunkan kekuatan komposit jika V_f kurang dari V_{crit} , sehingga keberadaan fiber atidak memberikan kontribusi kekuatan, fiber tidak bisa menghambat perpanjangan matriks sehingga fiber mengalami regangan sampai patah. Patahnya semua fiber tidak menyebabkan komposit patah mendadak. Keberadaan fiber mulai menaikkan kekuatan komposit jika V_f lebih besar dari V_{crit} , dan kekuatan komposit proporsional terhadap V_f .

Persentase beban yang ditanggung oleh fiber merupakan fungsi dari kekakuan atau modulus elastisitas dan fraksi volume pembentuknya. Sulistijono (2012) menunjukkan model hubungan tegangan fiber (σ_f), tegangan matriks (σ_m) dan tegangan komposit (σ_c), beban yang ditanggung fiber (P_f), beban yang ditanggung matriks (P_m), beban yang ditanggung komposit (P_c) terhadap

kekakuan fiber (E_f), kekakuan matriks (E_m) dan kekakuan komposit (E_c), seperti yang ditunjukkan pada persamaan 2.3, 2.4 dan 2.4:


$$\frac{\sigma_f}{\sigma_m} = \frac{E_f}{E_m} ; \quad \frac{\sigma_f}{\sigma_c} = \frac{E_f}{E_c} \quad (2.3)$$

$$\frac{P_f}{P_m} = \frac{E_f}{E_m} \cdot \frac{V_f}{V_m} \quad (2.4)$$


$$\frac{P_f}{P_c} = \frac{E_f/E_m}{E_f/E_m + V_m/V_f} \quad (2.5)$$

Dimana V_f adalah fraksi volume fiber dan V_m adalah fraksi volume matriks.

Dari persamaan 2.3 hingga 2.5 terlihat bahwa rasio tegangan bergantung pada rasio kekauannya, serta perbandingan beban yang ditanggung fiber terhadap matriks bergantung pada rasio kekakuannya dan fraksi volume fiber. Hubungan antara rasio beban yang ditanggung fiber dan fraksi beban fiber terhadap rasio kekakuan dan fraksi volume fiber bisa dilihat pada Gambar 2.14 dan 2.15.




Gambar 2.13. Tegangan maksimum unidireksional sebagai fungsi *fibre volume fraction* (Sulistijono, 2012)



Gambar 2.14. Hubungan antara rasio beban yang ditanggung fiber terhadap rasio kekakuan dan fraksi volume fiber (Sulistijono, 2012)

Fraksi beban yang disangga oleh fiber akan semakin besar jika rasio antara kekakuan fiber terhadap matriks dan fraksi volume fiber semakin besar, sehingga jika diinginkan beban yang tanggung oleh fiber sebesar mungkin maka harus dibuat komposit dengan fraksi volume fiber sebesar mungkin. Tetapi hal tersebut tidak selalu benar, pada kenyataannya jika fraksi volume fiber lebih dari 80% akan ada fiber yang tidak terikat oleh matriks karena banyaknya matriks tidak cukup untuk membasahi dan mengikat fiber sehingga terdapat rongga-rongga dan beban yang diterima oleh fiber yang tidak terikat matriks akan menanggung semua beban yang diterimanya karena tidak terdapat matriks untuk mendistribusikan beban ke fiber yang lain (Sulistijono, 2012).




Gambar 2.14. Hubungan antara fraksi beban fiber terhadap rasio kekakuan dan fraksi volume fiber (Sulistijono, 2012)

2.7.6 Pengaruh *fibre volume fraction* (arah pembebanan transversal)

Hubungan antara kekakuan komposit (E_c) terhadap kekakuan fiber (E_f), kekakuan matriks (E_m), fraksi volume fiber (V_f) dan fraksi volume matriks (V_m) pada kondisi terdeformasi elastik dengan pembebanan arah transversal terhadap orientasi fiber yang tersusun secara unidireksional dengan persamaan 2.6 (Sulistijono, 2012).

$$\frac{1}{E_c} = \frac{V_f}{E_f} + \frac{V_m}{E_m} \quad \text{atau} \quad E_c = \frac{1}{(V_f / E_f) + (V_m / E_m)} \quad (2.6)$$

Dari persamaan 2.6 terlihat bahwa kekakuan komposit tergantung pada rasio fraksi volume fiber terhadap kekakuan fiber. Jika pada komposit dengan pembebanan longitudinal kekuatan komposit akan naik dengan menaikkan fraksi volume fiber (lihat Gambar 2.13), hal tersebut tidak terjadi pada pembebanan transversal. Dengan menaikkan fraksi volume fiber tidak secara otomatis menaikkan kekakuan komposit, nilai kekakuan komposit bisa ditingkatkan dengan fraksi volume yang tinggi, seperti yang diperlihatkan pada Gambar 15. Dengan demikian, untuk menaikkan nilai kekakuan pada arah transversal harus ditambahkan fiber pada arah transversal, misalnya dengan membuat laminat dengan susunan lamina $[\pm 45/0_2/\pm 45]$.

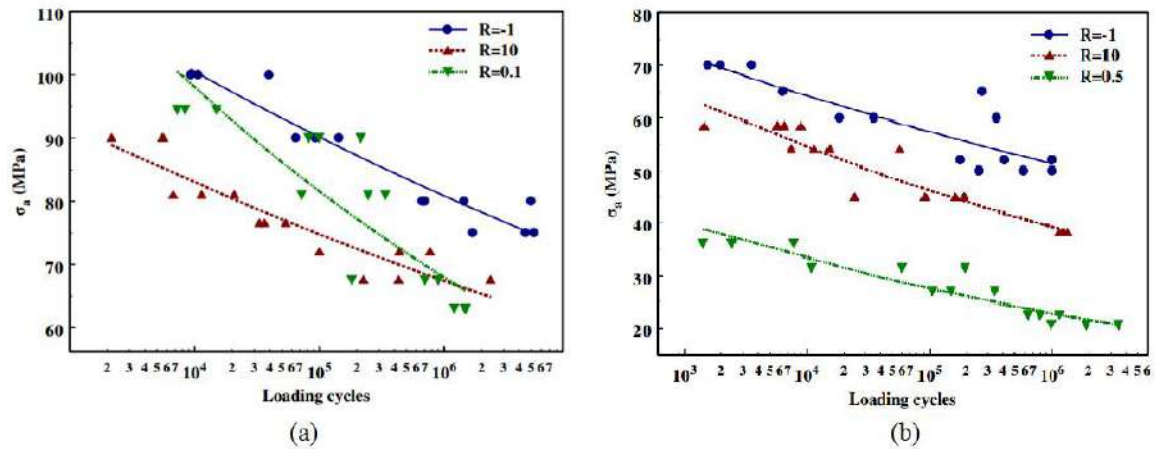


Gambar 2.15. Pengaruh fraksi beban fiber terhadap rasio kekakuan komposit pada arah pembebanan longitudinal (E_L) dan transversal (E_T) (Sulistijono, 2012)

2.7.7 Pengaruh *stress ratio*

Material komposit memiliki karakter yang berbeda terhadap beban tarik maupun kompresi. Ketika menerima beban tarik, kegagalan kelelahan didominasi oleh faktor fiber, tetapi jika menerima beban kompresi, lebih dipengaruhi oleh faktor matrix, fiber misalignment, defect pada material, dan lain-lain.

Efek *stress ratio* terhadap kelelahan adalah sangat berpengaruh baik untuk sistem material maupun *on-axis* dan *off-axis*. Contoh pengaruh *stress ratio* terhadap material komposit seperti yang ditunjukkan oleh Gambar 2.16, dengan material GFRP $[0/(\pm 45)_2/0]_T$, yang menerima beban dengan arah *on-axis* dan *off-axis*, dimana $R = -1$ adalah T-C, $R = 10$ adalah C-C dan $R = 0.1$ dan $R = 0.5$ adalah T-T



Gambar 2.16. Kelelahan material GFRP $[0/(\pm 45)_2/0]_T$, yang menerima beban dengan arah on-axis (a) dan off-axis (b) (Vassilopoulos dkk., 2007)

Mempertimbangkan sifat ketahanan terhadap arah pembebanan, yaitu kompresi dan beban tarik, merupakan hal yang sangat penting dalam pemilihan data kelelahan untuk proses training NN. Hidayat dkk. 2009) melakukan training NN pada material *E-Glass/Polyester*, $[90^\circ/0^\circ/\pm 45^\circ/0^\circ]_s$ dengan tiga set training dengan *stress ratio* (R) pada area yang berbeda, yaitu area T-T dan T-T, T-T dan T-C, serta T-T dan C-C, dimana T adalah notasi untuk *tension* dan C adalah *compression*. Berdasarkan hasil training, kesalahan terkecil ditunjukkan oleh training dengan area pembebanan yang sangat berlawanan, yaitu T-T dan C-C kemudian disusul oleh T-T dan T-C. Kecilnya kesalahan tersebut diperkirakan disebabkan karena penyebaran data yang lebih lebar sehingga lebih mendekati kondisi yang nyata.

Dalam beberapa studi prediksi umur kelelahan material komposit dengan NN, akurasi yang bagus ditunjukkan bila fungsi aproksimasi yang didapatkan dari training digunakan untuk memprediksi umur kelelahan material yang sama meskipun dengan kondisi pembebanan yang berbeda. Hidayat dkk. (2009) melakukan training dengan material *E-Glass/Epoxy*, $[\pm 45/0_4/\pm 45/]_s$, dengan data training set pada *stress ratio* (R) 0.1 dan 10 digunakan untuk memprediksi umur kelelahan pada material yang sama dengan R yang berbeda yaitu 0.5, -0.5, -1 dan 10. Nilai hasil prediksi dibandingkan data eksperimen menunjukkan angka akurasi yang tinggi yaitu ditunjukkan dengan *coefficient of determination* (R^2)

0.9526 hingga 0.9809.

Lee dkk. (1999) menggunakan metode NN untuk memprediksi umur kelelahan komposit HTA/982 berserat karbon dan komposit *E-glass*/913 dengan lay-up yang sama dengan menggunakan fungsi aproksimasi NN hasil training dengan material yang berbeda, yaitu komposit CFRP T800/5245, T800/924, IM7/977 and HTA/913, dengan *lay-up* yang sama yaitu $[(\pm 45,0_2)_2]_s$. Hasil prediksi menunjukkan kesalahan yang sangat tinggi, untuk prediksi komposit HTA/982 dicapai dengan RMSE mendekati 100%, sedangkan untuk prediksi komposit E-glass/913 dicapai dengan RMSE mendekati 170%.


Dari beberapa paparan di atas terdapat beberapa poin yang bisa ditarik tentang beberapa hal yang berpengaruh terhadap perilaku kelelahan komposit, antara lain:

- *Final properties* dari sebuah komposit yang paling utama ditentukan oleh *composite system*, antara lain faktor *properties* dari *fibres*, *properties* dari *matrix*, persentase *fibres* atau *fibre volume fraction*, serta orientasi dan geometri dari *fibrous reinforcement*.
- Material komposit bersifat *anisotropic*, artinya memiliki *properties* yang berbeda untuk orientasi yang berbeda, sebagai contoh adalah modulus elastisitas (E), dimana $E_{0^\circ} \neq E_{45^\circ} \neq E_{90^\circ}$. Seperti halnya dengan modulus elastisitas, *properties* lainnya juga tergantung pada orientasinya, seperti *ultimate strength*, *poisson's ratio* dan koefisien ekspansi termal.
- Sudut orientasi beban (*on-axis/off-axis*) sangat mempengaruhi umur kelelahan karena material komposit memiliki sifat *anisotropic*.
- Tingkat tegangan maksimum, tegangan minimum dan *stress ratio* sangat mempengaruhi umur kelelahan komposit
- Data kelelahan komposit memiliki *scatter* yang lebih tinggi dari metal. Besarnya *scatter* dipengaruhi oleh beberapa parameter (yang independen), antara lain *properties* yang bervariasi di dalam *fibre* dan *matrix*, kondisi *manufacturing*, faktor kupon (geometri, ukuran dan *pre-treatment*), *level* dari *stress/strain* dan nilai *stress ratio*, dan *test set up*.

2.8 Artificial Neural Network (NN)

NN merupakan salah satu metode fungsi aproksimasi, dimana sistemnya terinspirasi oleh sistem syaraf makhluk hidup, dan telah banyak digunakan untuk menyelesaikan banyak permasalahan di dalam bidang pengetahuan dan rancang bangun. Seperti yang terjadi pada makhluk hidup, NN mampu belajar dari contoh-contoh yang dia terima, melalui proses training. Berdasarkan contoh-contoh tersebut menjadikan NN memiliki kemampuan untuk memecahkan permasalahan yang tidak linier yang kompleks, fungsi hubungan yang multi-dimensional, tanpa memerlukan pengetahuan sebelumnya tentang sifat-sifatnya.

Struktur jaringan syaraf makhluk hidup yang mendasar ditunjukkan pada Gambar 2.17 (a). *Cell body* menerima sinyal listrik (berbentuk ion-ion) melalui dendrites, jika kumpulan dari sinyal-sinyal tersebut melebihi batas ambang maka *cell body* akan menembakkan sinyal yang berjalan pada *axon*. Model jaringan syaraf buatan yang meniru atau terinspirasi oleh jaringan syaraf makhluk hidup (NN) tersebut digambarkan seperti yang ditunjukkan pada gambar gambar 2.16 (b). Satu set input data (X_1, X_2, \dots, X_N), dimana $i = 1$ hingga N , memasuki McCulloch-Pitts neuron, dimana setiap input data memiliki bobot tertentu yaitu (W_1, W_2, \dots, W_N), dimana $i = 1$ hingga N . Penjumlahan dari set data yang memiliki bobot tersebut harus melewati sebuah fungsi aktivasi yang *non-linear* agar memiliki nilai yang lebih tinggi dari nilai ambang batas agar menghasilkan output y .




Gambar 2.17. (a) Model struktur jaringan syaraf makhluk hidup. (b) Model NN yang terinspirasi oleh model struktur jaringan syaraf makhluk hidup.

2.9.1 Proses Learning

Learning merupakan proses dimana neural network secara sendirinya melakukan adaptasi terhadap *stimulus* dan akhirnya (setelah melakukan penyesuaian bobot dan bias) menghasilkan respon tertentu. Dua kategori learning yang utama di dalam neural network adalah *supervised learning* dan *unsupervised learning*. Pada *supervised learning*, respon keluaran dibandingkan dengan respon target tertentu, jika respon keluaran berbeda dengan respon target maka network menghasilkan sinyal kesalahan, berdasarkan sinyal kesalahan tersebut kemudian network melakukan penyesuaian ulang terhadap bobot yang sudah ada, proses tersebut diulang-ulang terus sehingga menghasilkan output nilai kesalahan yang serendah mungkin. Sebaliknya, pada *unsupervised learning* tidak membutuhkan *target output*. Selama masa training, neural network menerima input dengan pola tertentu, kemudian network akan mengenali pola yang mirip dan menggolongkannya menjadi beberapa pola-pola yang mirip.

2.9.2 Multilayer Perceptrons (MLP)

Arsitektur MLP dengan sebuah hidden layer dengan satu *output* ditunjukkan oleh Gambar 2.18.



Gambar 2.18. Arsitektur *MLP* dengan satu hidden layer dan single output (Hidayat dkk. 2009)

Notasi yang disebutkan dalam arsitektur pada Gambar 2.18 antara lain:

$p_1, p_2, p_3, \dots, p_L$ = input set

L = jumlah elemen pada input vector

S = jumlah *hidden nodes*

n = penjumlahan dari input dengan pembobotan (*weighted input*)

a = output dari fungsi aktivasi

$w^1_{j,i}$ dan b^1_j = bobot *input* dan *bias*; dimana $i = 1$ hingga L dan $j = 1$ hingga S

$w^2_{1,j}$ dan b_o = bobot *layer* dan *output bias*

y = MLP output



= simbol untuk fungsi aktivasi non-linier.



= simbol untuk fungsi aktivasi linier: $y = f(x) = x$

Superscripts 1 dan 2 mewakili hidden layer pertama dan hidden layer yang kedua.

Sesuai Gambar 2.18, input set, bobot dan bias dalam bentuk matrix dan vektor bisa dilihat pada persamaan 2.7 hingga 2.11 di bawah.

Matrix bobot pada hidden layer:

$$w^1_{j,i} = \begin{bmatrix} w^1_{1,1} & w^1_{1,2} & w^1_{1,3} & \dots & w^1_{1,L} \\ w^1_{2,1} & w^1_{2,2} & w^1_{2,3} & \dots & w^1_{2,L} \\ \dots & \dots & \dots & \dots & \dots \\ w^1_{S,1} & w^1_{S,2} & w^1_{S,3} & \dots & w^1_{S,L} \end{bmatrix} \quad (2.7)$$

Vektor input layer:

$$p_i = [p_1, p_2, p_3, \dots, p_L]^T \quad (2.8)$$

Vektor bias pada hidden layer:

$$b^1_j = [b_1, b_2, b_3, \dots, b_L]^T \quad (2.9)$$

Vektor bobot pada hidden layer:

$$w^2_{1,j} = [w^2_{1,1}, w^2_{1,2}, \dots, w^2_{1,S}] \quad (2.10)$$

Vektor bias pada output layer (1-dimensi):

$$b_o = [b_o] \quad (2.11)$$

Learning di dalam NN dilakukan dengan cara menyesuaikan nilai masing-masing bobot berdasarkan input set. Bobot disesuaikan nilainya dengan

serangkaian aturan learning dengan tujuan fungsi tujuan bisa diminimalkan.

Jika (P, T) merupakan pasangan variabel acak dimana nilai P dan T secara berurut adalah $P = \mathbb{R}^m$ dan $T = \mathbb{R}$. Regresi dari T pada P merupakan fungsi nilai P , yaitu $f: P \rightarrow T$, menjadikan nilai dari T tergantung P , $E(T|P)$.

Misalkan terdapat nilai acak $O_1^Q = \{(P_1, T_1), \dots, (P_Q, T_Q)\}$ dengan ukuran Q , yang merupakan distribusi dari (P, T) berupa set observasi. Untuk $Q \geq 1$, \hat{f}_Q merupakan estimator dari f berdasarkan sampel acak, yaitu dengan pemetaan $\hat{f}_Q: O_1^Q \rightarrow \hat{f}_Q(O_1^Q, \cdot)$, dimana untuk $O_1^Q, p \rightarrow \hat{f}_Q(O_1^Q, p)$ yang sudah tetap, merupakan sebuah estimasi dari fungsi regresi $f(p)$.

Untuk lebih mudah, P dan T dianggap sebagai set dari variabel input dan output. Dengan data set observasi O , learning NN untuk realisasi fungsi aproksimasi \hat{f} dengan cara menyesuaikan vektor parameter bobot (\mathbf{w}) dan bias (\mathbf{b}) dengan menggunakan suatu algoritma learning tertentu sehingga \hat{f} meminimalkan fungsi tujuan atau empirical error seperti pada persamaan 2.12, yang memiliki kemampuan generalisasi yang bagus atau menghasilkan output yang bagus ketika sebuah vektor inputan baru yaitu \mathbf{p}_{test} yang belum pernah digunakan sebelumnya dimasukkan ke dalam NN.

$$E(\mathbf{w}) = \sum_{q=1}^Q [t_q - \hat{f}(\mathbf{p}_q; \mathbf{w})]^2 \quad (2.12)$$

Fungsi estimasi \hat{f} yang direalisasikan dengan jaringan MLP pada gambar 2.18 dengan set training O dituliskan seperti pada persamaan 2.13, dimana $\tau(\cdot)$ adalah fungsi aktivasi non-linier yang digunakan pada *hidden nodes*.

$$\hat{f}(\mathbf{p}; \mathbf{w}) = \sum_{i=1}^S \mathbf{w}_{1,i}^2 \tau(\mathbf{w}_{i,j}^1 \mathbf{p} + \mathbf{b}_i) + \mathbf{b}_o \quad (2.13)$$

Beberapa fungsi aktivasi non-linier yang umum digunakan adalah seperti pada persamaan 2.14, 2.15, 2.16 dan 2.17 (Haykin, 2009).

Threshold function:

$$\tau(n) = \begin{cases} 1 & \text{Jika } n \geq 0 \\ 0 & \text{Jika } n < 0 \end{cases} \quad (2.14)$$

Logistic-sigmoid function:

$$\tau(n) = \frac{1}{(1 + e^{-n})} \quad (2.15)$$

Signum function:

$$\tau(n) = \begin{cases} 1 & \text{Jika } n > 0 \\ 0 & \text{Jika } n = 0 \\ -1 & \text{Jika } n < 0 \end{cases} \quad (2.16)$$

Hyperbolic tangent function:

$$\tau(n) = \tanh(n) \quad (2.17)$$

2.9 Algoritma Optimasi Metaheuristik

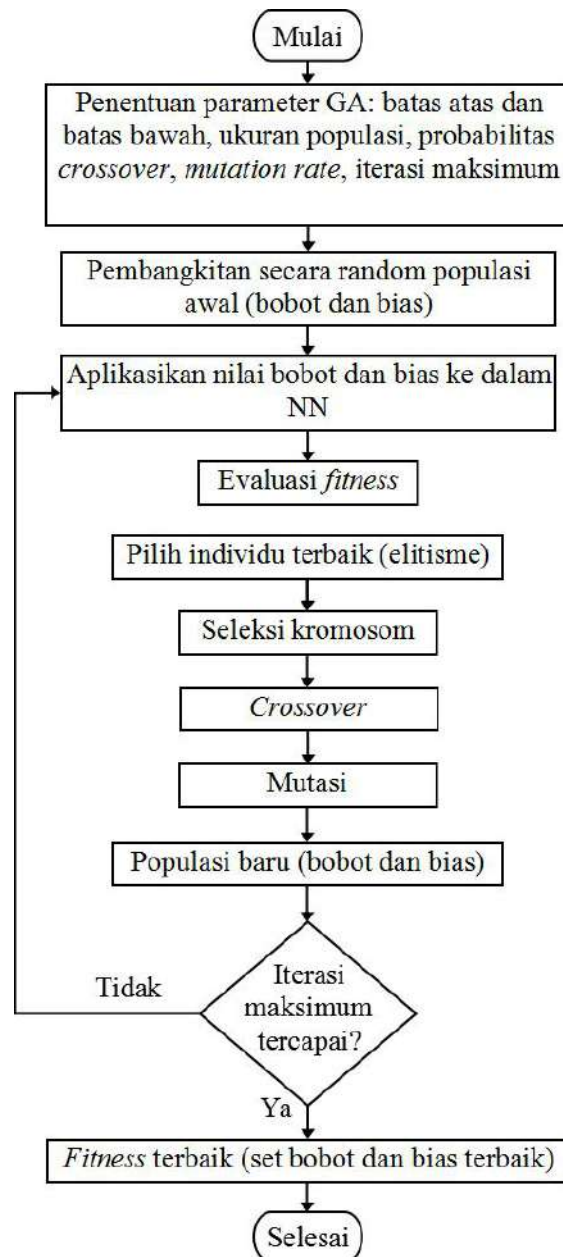
Kebanyakan proses training NN menggunakan algoritma klasik, yaitu diantaranya adalah *gradient-based search* dan *direct search* yang memiliki keunggulan yaitu dalam hal kecepatan pencarian nilai optimum karena dalam pencarian sudah diarahkan di awal serta dengan adanya *gradient* pada proses perhitungannya, namun demikian, kedua metode tersebut memiliki kekurangan yaitu kecenderungan untuk terjebak pada nilai *local minima*. Berbeda dengan pada metode klasik, algoritma metaheuristik memiliki keunggulan yaitu kemampuannya untuk keluar dari *local optima* sehingga bisa didapatkan solusi global (Masoud dkk., 2013, Santosa dkk., 2011).

Metaheuristik adalah pendekatan komputasi untuk mencari solusi optimal atau mendekati optimal dari suatu problem optimasi dengan cara mencoba secara iteratif untuk memperbaiki kandidat solusi dengan memperhatikan batasan kualitas solusi yang diinginkan. Dalam metaheuristik tidak ada asumsi mengenai problem yang dioptimalkan dan bisa mencari solusi dalam ruang pencarian (*search space*) yang besar. Metaheuristik tidak menjamin solusi optimal akan ditemukan. Dengan kata lain, metaheuristik adalah metode untuk mencari solusi yang memadukan interaksi antara prosedur pencarian lokal dan strategi yang lebih tinggi untuk menciptakan proses yang mampu keluar dari titik-titik *local optima* dan melakukan pencarian di ruang solusi untuk menemukan solusi global (Santosa dkk., 2011).

2.10.1 Genetic Algorithm (GA)

GA termasuk di dalam kelompok algoritma evolusi. GA didasarkan pada prinsip-prinsip genetika dan seleksi alam. Elemen-elemen dasar dari genetika adalah: reproduksi, *crossover* dan mutasi (Santosa dkk., 2011).

Prosedur GA adalah seperti pada diagram alir pada Gambar 2.19.



Gambar 2.19. Diagram alir *genetic algorithm* (GA)

2.10.1.1 Pembangkitan populasi awal

Sebelum dilakukan pembangkitan populasi awal, ditentukan dulu beberapa nilai parameter GA antara lain nilai batas atas dan batas bawah, ukuran populasi, probabilitas *crossover*, *mutation rate*, dan iterasi maksimum.

Populasi yang dibangkitkan adalah bilangan random, yang disebut dengan individu, dengan ukuran atau jumlah tertentu, dengan tujuan agar bisa muncul individu yang terbaik yang kemudian akan berlanjut pada seleksi alam selanjutnya. Dalam tesis ini digunakan nilai kontinyu. Masing-masing kromosom (x) dibangkitkan dengan menggunakan rumus 2.18, dimana notasi BB adalah batas bawah, BA adalah batas atas dan r adalah nilai random. Dalam prakteknya, nilai random r dipilih antara (0,1).

$$x = BB + r(BA - BB) \quad (2.18)$$

Suatu populasi terdiri dari beberapa individu, dimana setiap individu merupakan satu set bobot dan bias.

2.10.1.2 Evaluasi *fitness*

Bobot dan bias dari tiap individu diaplikasikan ke dalam jaringan NN dan dievaluasi nilai error-nya berdasarkan fungsi tujuan seperti yang ditunjukkan pada persamaan 2.12 yang ditunjukkan ulang di bawah ini:

$$E(w) = \sum_{q=1}^Q [t_q - \hat{f}(p_q; w)]^2 \quad (2.12)$$

Fitness digunakan untuk mengukur tingkat kebaikan atau kesesuaian (*fitness*) suatu solusi yang dicari. Dalam tesis ini, fungsi *fitness* yang dicari menggunakan persamaan 2.19. Untuk masalah minimasi, semakin tinggi nilai *fitness* suatu individu menunjukkan kesalahan yang dihasilkan semakin kecil.

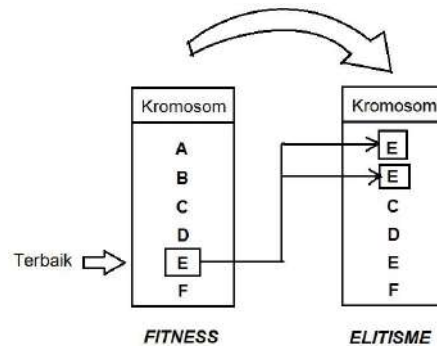
$$F(x) = \frac{1}{(1 + f(x))} \quad (2.19)$$

Dimana $F(x)$ adalah *fitness*, dan $f(x)$ adalah fungsi tujuan NN.

2.10.1.3 Elitisme

Elitisme bertujuan untuk mempertahankan kromosom yang terbaik dan

akan meneruskan untuk proses evolusi berikutnya, sehingga romosom-kromosom tersebut akan muncul pada proses evolusi selanjutnya. Kromosom-kromosom yang terbaik tersebut akan menggantikan kromosom lain yang memiliki *fitness* lebih kecil, sehingga kromosom yang kurang baik akan digantikan dengan kromosom yang terbaik, yang diharapkan bisa menghasilkan keturunan yang lebih baik. Ilustrasi elitisme ditunjukkan pada Gambar 2.20.



Gambar 2.20. Ilustrasi proses elitisme

2.10.1.4 Seleksi kromosom

Proses seleksi kromosom adalah untuk memilih anggota populasi sebagai induk (induk I dan induk II) untuk dilakukan *crossover*. Seleksi dilakukan dengan dengan memilih kromosom yang mempunyai nilai *fitness* tertinggi.

2.10.1.5 Crossover

Crossover dilakukan terhadap induk I dan Gen II dari hasil seleksi kromosom. *Crossover* dilakukan dengan *arithmetic crossover*. Prosedurnya adalah sebagai berikut:

- Bangkitkan bilangan random r (0,1), jika $r > Ps$ (probabilitas *crossover*) maka induk I dan induk II akan langsung menggantikan dua kromosom yang tidak elit. Jika $r < Ps$ maka dua kromosom baru pengganti dua kromosom tidak elit didapatkan dengan persamaan 2.20 dan 2.21.

$$Xs' = r * [\text{induk I}] + (1 - r) * [\text{induk II}] \quad (2.20)$$

$$Xs'' = (1 - r) * [\text{induk I}] + r * [\text{induk II}] \quad (2.21)$$

- Lakukan dengan cara yang sama untuk mengganti kromosom lain yang tidak elit.

2.10.1.6 Mutasi

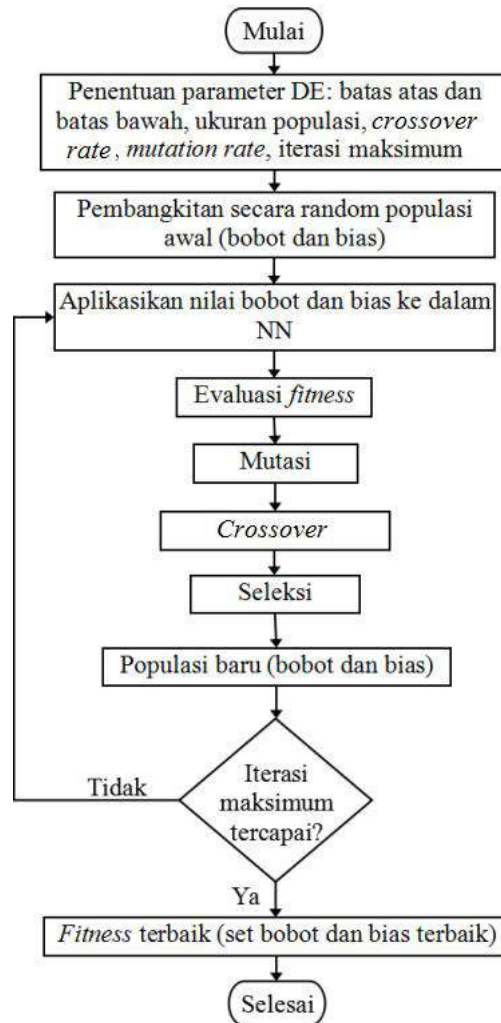
Mutasi dilakukan dengan cara memilih salah satu atau lebih kromosom mana yang akan mengalami mutasi secara acak. Kromosom ini kemudian diisi dengan nilai baru secara acak. Pemilihan kromosom mana yang akan mengalami mutasi dilakukan menggunakan parameter probabilitas mutasi. Misal diinginkan 10% dari populasi mengalami mutasi, maka jika ada 6 kromosom hanya satu kromosom saja yang akan terjadi mutasi. Ini dilakukan dengan pembulatan ke atas terhadap 0.1×6 . Kromosom baru dibangkitkan menggunakan persamaan 2.22, dengan bilangan random r , yang umumnya menggunakan range (0,1)

$$x = BB + r(BA - BB) \quad (2.22)$$

2.10.2 *Differential Evolution* (DE)

Algoritma DE termasuk metode pencarian stokastik dan berdasarkan populasi (*population based search*). DE mempunyai kemiripan dengan algoritma evolusi yang lain, tetapi memiliki perbedaan dalam hal informasi jarak dan arah dari populasi yang digunakan untuk memandu proses pencarian solusi yang lebih baik.

Prosedur DE adalah seperti pada diagram alir pada Gambar 2.21.



Gambar 2.21. Diagram alir algoritma DE

2.10.2.1 Pembangkitan populasi awal

Sebelum dilakukan pembangkitan populasi awal vektor variabel yang dicari, perlu dilakukan penentuan ukuran populasi N , *crossover rate* Cr , *mutation rate* F , batas atas (UB) dan batas bawah (LB).

Untuk pembangkitan nilai awal variabel generasi ke-0, variabel ke- j dan vektor- i bisa diwakili dengan persamaan 2.23.

$$x_{j,i,0} = LB_j + rand_j(0,1)(UB_j - LB_j) \quad (2.23)$$

Dimana $rand_j(0,1)$ adalah bilangan random dalam range (0,1). Index j menunjukkan variabel ke- j . Misalkan dalam kasus minimasi fungsi dengan dua variabel maka j akan bernilai 1 dan 2.

2.10.2.2 Evaluasi *fitness*

Bobot dan bias dari tiap individu diaplikasikan ke dalam jaringan NN dan dievaluasi nilai *error*-nya berdasarkan fungsi tujuan seperti yang ditunjukkan pada persamaan 2.12 yang ditunjukkan ulang di bawah ini:

$$E(w) = \sum_{q=1}^Q [t_q - \hat{f}(p_q; w)]^2 \quad (2.12)$$

Fitness digunakan untuk mengukur tingkat kebaikan atau kesesuaian (*fitness*) suatu solusi yang dicari. Dalam tesis ini, fungsi *fitness* yang dicari menggunakan persamaan 2.12. Untuk masalah minimasi, semakin kecil nilai *fitness* suatu individu menunjukkan kesalahan yang dihasilkan semakin kecil.

2.10.2.3 Mutasi

DE akan memutasi dan mengkombinasi populasi awal untuk menghasilkan populasi dengan ukuran N vektor percobaan. Dalam DE, mutasi dilakukan dengan cara menambahkan perbedaan dua vektor terhadap vektor ketiga dengan persamaan 2.24.

$$v_{i,g} = x_{r0,g} + F(x_{r1,g} - x_{r2,g}) \quad (2.24)$$

Terlihat bahwa perbedaan dua vektor yang dipilih secara random perlu diskala dulu sebelum ditambahkan ke vektor ketiga $x_{r0,g}$. Faktor skala $F \in (0,1)$ bernilai real positif yang mengendalikan tingkat pertumbuhan populasi. Indeks vektor bias r_0 dapat ditentukan dengan cara random yang berbeda dengan indeks untuk vektor target i . Selain berbeda satu sama lain dan berbeda dengan indeks untuk vektor basis dan vektor target, indeks vektor selisih r_1 dan r_2 , juga dipilih sekali per muatan.

2.10.2.4 *Crossover*

Pada tahap ini DE menyilangkan setiap vektor $x_{i,g}$ dengan vektor mutan $v_{i,g}$, untuk membentuk vektor hasil persilangan $u_{i,g}$ dengan kriteria:

$$u_{i,g} = u_{j,i,g} = \begin{cases} u_{j,i,g} & \text{jika } (\text{rand}(0,1)) \leq Cr \text{ atau } j=j_{rand} \\ x_{j,i,g} & \text{untuk sebaliknya} \end{cases} \quad (2.25)$$

Crossover rate $Cr \in (0,1)$ adalah nilai yang didefinisikan untuk mengendalikan fraksi nilai variabel yang disalin dari mutan.

2.10.2.5 Seleksi

Dari vektor trial $u_{i,g}$, mempunyai nilai fungsi tujuan yang lebih kecil dari fungsi tujuan vektor targetnya, $x_{i,g}$, maka $u_{i,g}$ akan menggantikan posisi $x_{i,g}$ dalam populasi pada generasi berikutnya. Jika terjadi sebaliknya, vektor target akan tetap pada posisinya dalam populasi.

2.10.2.6 Mengendalikan faktor Cr dan F

Chakraborty (2008) menyebutkan, untuk mendapatkan hasil yang baik maka Cr tidak boleh bernilai rendah, berdasarkan beberapa penelitian nilai Cr yang terbaik adalah pada kisaran 0.8 hingga 1. Selain itu nilai F harus dikendalikan agar tidak lebih kecil dari $F_{critical}$.

$$F_{critical} = \sqrt{\frac{\left(1 - \frac{Cr}{2}\right)}{N}} \quad (2.26)$$

Persamaan 2.26 menunjukkan rumus $F_{critical}$, dimana N adalah ukuran populasi.

2.10.2.7 Menangani pelanggaran batas

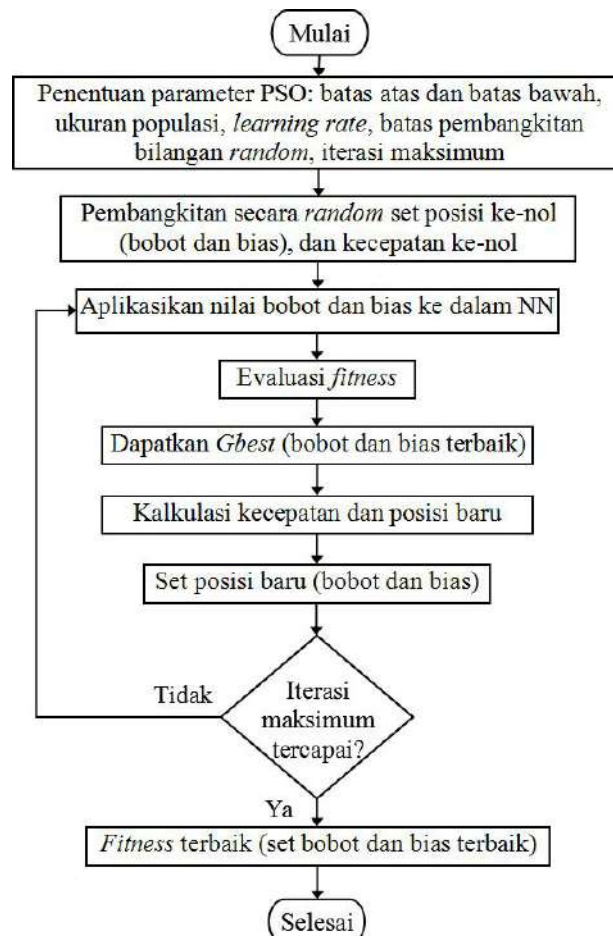
Ada kalanya pada saat mutasi menghasilkan beberapa vektor populasi yang keluar dari nilai batas atas dan batas bawah, dan jika hasil tersebut diaplikasikan ke NN akan menghasilkan nilai error yang tinggi. Jika kejadian tersebut muncul maka vektor populasi tersebut harus dikembalikan ke area di dalam batas atas dan batas bawah dengan cara *random reinitialization*, yaitu dengan menggunakan persamaan 2.27 (Price dkk., 2005).

$$x_{j,i,0} = LB_j + \text{rand}_j(0,1)(UB_j - LB_j) \quad (2.27)$$

2.10.3 Particle Swarm Optimization (PSO)

Metode PSO terinspirasi oleh perilaku suatu kelompok binatang yang dengan usaha yang bersama-sama mampu melakukan pengaturan sendiri. Sebagai contoh adalah perilaku sekelompok burung yang sedang terbang, lebah, atau semut. Individu di dalam kawanan (*swarm*) biasa disebut dengan agen. Masing-masing agen bertindak berdasarkan aturan lokal yang sangat sederhana, dan meskipun tidak ada pusat kendali yang memerintah bagaimana masing-masing agen harusnya bereaksi, pada akhirnya terbentuk interaksi antara agen dan kelompok. Hal ini yang menyebabkan mmunculnya periaku kecerdasan global yang tidak disadari oleh masing-masing agen di dalam suatu kelompok atau kawanan (Santosa dkk., 2011).

Prosedur algoritma PSO dalam bentuk diagram alir ditunjukkan pada Gambar 2.22.



Gambar 2.22. Diagram alir algoritma PSO

2.10.3.1 Pembangkitan awal populasi (posisi ke-nol dan kecepatan ke-nol)

Sebelum dilakukan pembangkitan populasi awal, beberapa parameter PSO harus ditentukan terlebih dahulu, antara lain batas atas dan batas bawah, ukuran populasi (N), learning rate, batas pembangkitan bilangan random, iterasi maksimum. Suatu populasi terdiri dari N kelompok dan setiap kelompok terdiri dari beberapa partikel yang merupakan bobot dan bias.

Posisi awal partikel $X_j^{(0)}$ (0 adalah iterasi awal, j adalah urutan kelompok: $j = 1, \dots, N$) dibangkitkan secara random dengan rentang X_{max} dan X_{min} , dan ditunjukkan pada persamaan 2.28. Pada penjelasan selanjutnya posisi partikel pada kelompok ke- j pada iterasi ke- i disebut dengan $X_j^{(i)}$ dan kecepatan partikel pada kelompok ke- j pada iterasi ke- i disebut dengan $V_j^{(i)}$. R

$$X_j^{(0)} = BB + \text{rand}(0,1) * (BA - BB) \quad (2.28)$$

Dimana BA adalah nilai batas atas dan BB adalah nilai batas bawah posisi partikel, dimana keduanya mengendalikan posisi partikel.

Kecepatan semua partikel yang dibangkitkan di awal adalah $V_j^{(0)} = 0$.

2.10.3.2 Evaluasi *fitness* (awal)

Bobot dan bias awal (posisi partikel ke-nol) dari tiap kelompok diaplikasikan ke dalam jaringan NN dan dievaluasi nilai error-nya berdasarkan fungsi tujuan seperti yang ditunjukkan pada persamaan 2.12 yang ditunjukkan ulang di bawah ini:

$$E(w) = \sum_{q=1}^Q [t_q - \hat{f}(p_q; w)]^2 \quad (2.12)$$

Fitness digunakan untuk mengukur tingkat kebaikan atau kesesuaian (*fitness*) suatu solusi yang dicari. Dalam tesis ini, fungsi *fitness* yang dicari menggunakan persamaan 2.12. Untuk masalah minimasi, semakin kecil nilai *fitness* suatu individu menunjukkan kesalahan yang dihasilkan semakin kecil.

2.10.3.3 *Pbest* dan *Gbest*

Pbest atau *local best* adalah posisi terbaik dari tiap kelompok yang ditentukan oleh *fitness* terbaik pada semua iterasi yang sudah dijalani. Pada kasus minimasi, *fitness* terbaik adalah yang memiliki nilai fungsi tujuan yang terkecil.

Gbest atau *global best* adalah nilai *Pbest* terbaik di antara semua partikel yang ditemui pada semua iterasi yang sudah dijalani yang ditentukan oleh *fitness* terbaik pada semua iterasi yang sudah dijalani.

2.10.3.4 Kecepatan partikel V_j

Kecepatan partikel ke- j pada iterasi ke- i dihitung dengan persamaan 2.29 (Parsopoulos dkk., 2010).

$$V_j^{(i)} = W_i * V_j^{(i-1)} + c_1 r_1 [Pbest_{j,i} - X_j^{(i-1)}] + c_2 r_2 [Gbest - X_j^{(i-1)}] \quad (2.29)$$

Dimana masing-masing c_1 dan c_2 masing-masing adalah *learning rate* untuk kemampuan individu (cognitive) dan pengaruh sosial (kawanan), sedangkan r_1 dan r_2 adalah bilangan random yang dibangkitkan dengan nilai dalam range (0,1).

Nilai W_i adalah inersia kecepatan pada iterasi ke- i yang nilainya selalu berubah pada setiap iterasi. Nilai W_i ditunjukkan pada persamaan 2.30 (Parsopoulos dkk., 2010).

$$W_i = W_{max} - (W_{max} - W_{min}) * \frac{i}{I_{max}} \quad (2.30)$$

Dimana W_{max} dan W_{min} adalah nilai maksimum dan minimum dari inersia kecepatan. I_{max} adalah iterasi maksimum.

2.10.3.5 Posisi partikel X_j

Kecepatan partikel ke- j pada iterasi ke- i dihitung dengan persamaan 2.31 (Parsopoulos, 2010).

$$X_j^{(i)} = X_j^{(i-1)} + V_j^{(i)} \quad (2.31)$$

Pada setiap akhir iterasi, posisi partikel terbaru ditentukan dengan membandingkan antara *fitness* posisi iterasi baru dengan posisi iterasi sebelumnya. Jika *fitness* dari posisi baru lebih kecil dari posisi sebelumnya maka posisi partikel baru yang digunakan, jika terjadi sebaliknya maka posisi partikel lama yang digunakan, seperti yang ditunjukkan pada persamaan 2.32 (Parsopoulos dkk., 2010).

$$X_j^{(i)} = \begin{cases} X_j^{(i)} & \text{Jika } \text{fitness}(X_j^{(i)}) \leq \text{Jika } \text{fitness}(X_j^{(i-1)}) \\ X_j^{(i-1)} & \text{Jika sebaliknya} \end{cases} \quad (2.32)$$

2.10.3.6 Evaluasi *fitness* akhir


Bobot dan bias dari tiap kelompok pada populasi akhir diaplikasikan ke dalam jaringan NN dan dievaluasi nilai error-nya berdasarkan fungsi tujuan seperti yang ditunjukkan pada persamaan 2.12 yang ditunjukkan ulang di bawah ini:

$$E(w) = \sum_{q=1}^Q [t_q - \hat{f}(p_q; w)]^2 \quad (2.12)$$

Fitness digunakan untuk mengukur tingkat kebaikan atau kesesuaian (*fitness*) suatu solusi yang dicari. Fungsi *fitness* yang dicari menggunakan persamaan 2.12. Untuk masalah minimasi, semakin kecil nilai *fitness* suatu individu menunjukkan kesalahan yang dihasilkan semakin kecil.

2.10.3.7 Pengaruh nilai learning rate c_1 dan c_2

Besarnya nilai c_1 dan c_2 mempengaruhi area kandidat posisi pada iterasi selanjutnya, semakin besar nilainya maka area kandidat posisinya akan semakin luas sehingga mengakibatkan *fitness* yang semakin besar atau solusinya semakin *divergen*. Sebagai ilustrasi ditunjukkan pada Gambar 2.23



Gambar 2.23. Area kandidat posisi baru partikel $X^{(i-1)}$ (tanda silang) dengan $Pbest$ (tanda bintang) dan $Gbest$ (tanda kotak) dari (A) $c_1 = c_2 = 1$ (B) $c_1 = c_2 = 2$ (Parsopoulos dkk., 2010)

2.10.3.8 Menangani pelanggaran batas kecepatan

Salah satu kejadian yang bisa terjadi di algoritma adalah efek *swarm explosion*, yaitu menghasilkan solusi baru yang divergen, yang disebabkan oleh meningkatnya kecepatan partikel yang tidak terkontrol. Untuk menghindari hal tersebut, kecepatan setiap partikel harus dikendalikan, yaitu tidak boleh melebihi kecepatan maksimum (v_{max}), seperti yang ditunjukkan pada persamaan 2.33 (Parsopoulos dkk., 2010).

$$v^{(i)} = \begin{cases} v_{max} & \text{Jika } v^{(i)} > v_{max} \\ -v_{max} & \text{Jika } v^{(i)} < -v_{max} \end{cases} \quad (2.33)$$

Dimana:

$$v_{max} = \frac{BA - BB}{k} \quad (2.34)$$

BA dan BB secara berurutan adalah nilai batas atas dan batas bawah posisi partikel dan k adalah nilai konstanta yang umumnya digunakan angka 2.

2.10.3.9 Menangani pelanggaran batas posisi partikel

Ada kalanya pada setelah terjadi perubahan, suatu partikel berada pada posisi diluar nilai batas atas dan batas bawah, dan jika hasil tersebut diaplikasikan ke NN akan menghasilkan nilai error yang tinggi. Jika kejadian tersebut muncul maka partikel tersebut harus dikembalikan ke area di dalam batas atas dan batas bawah dengan cara *random reinitialization*, yaitu dengan menggunakan persamaan 2.35 (Marini dkk., 2015).

$$X = BB + rand(0,1)(BA - BB) \quad (2.35)$$

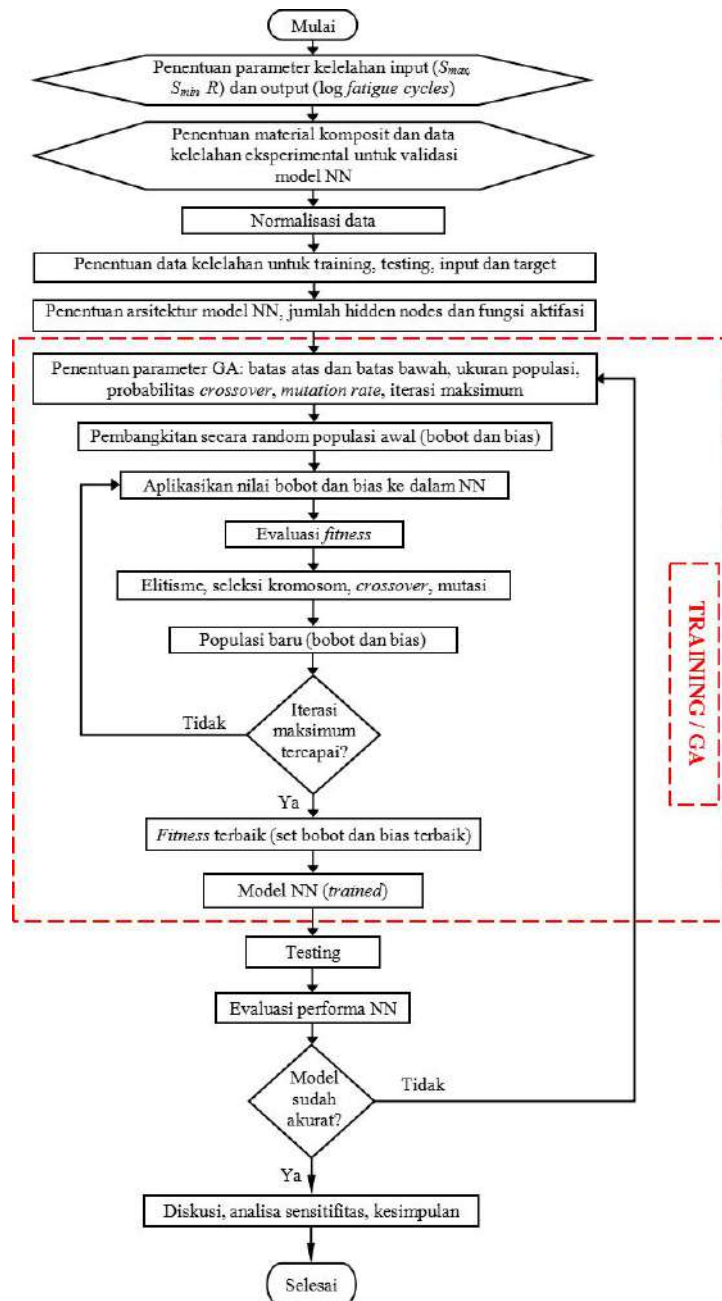
(Halaman ini sengaja dikosongkan)

BAB 3

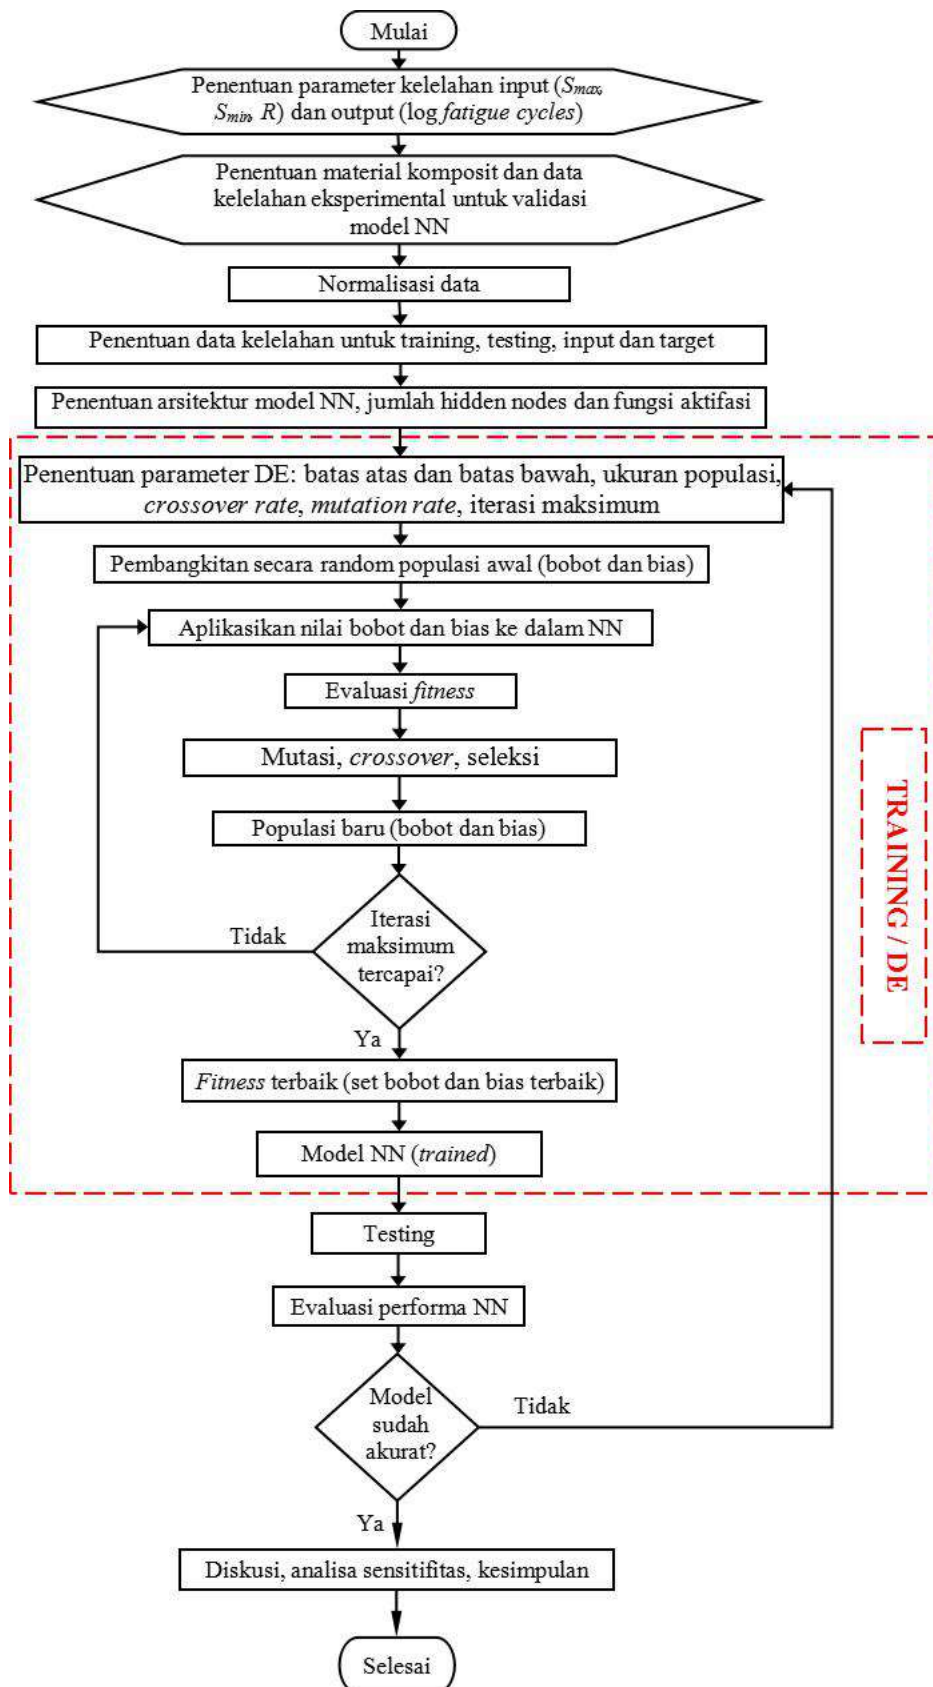
METODE PENELITIAN

3.1 Diagram Alir Pemodelan NN

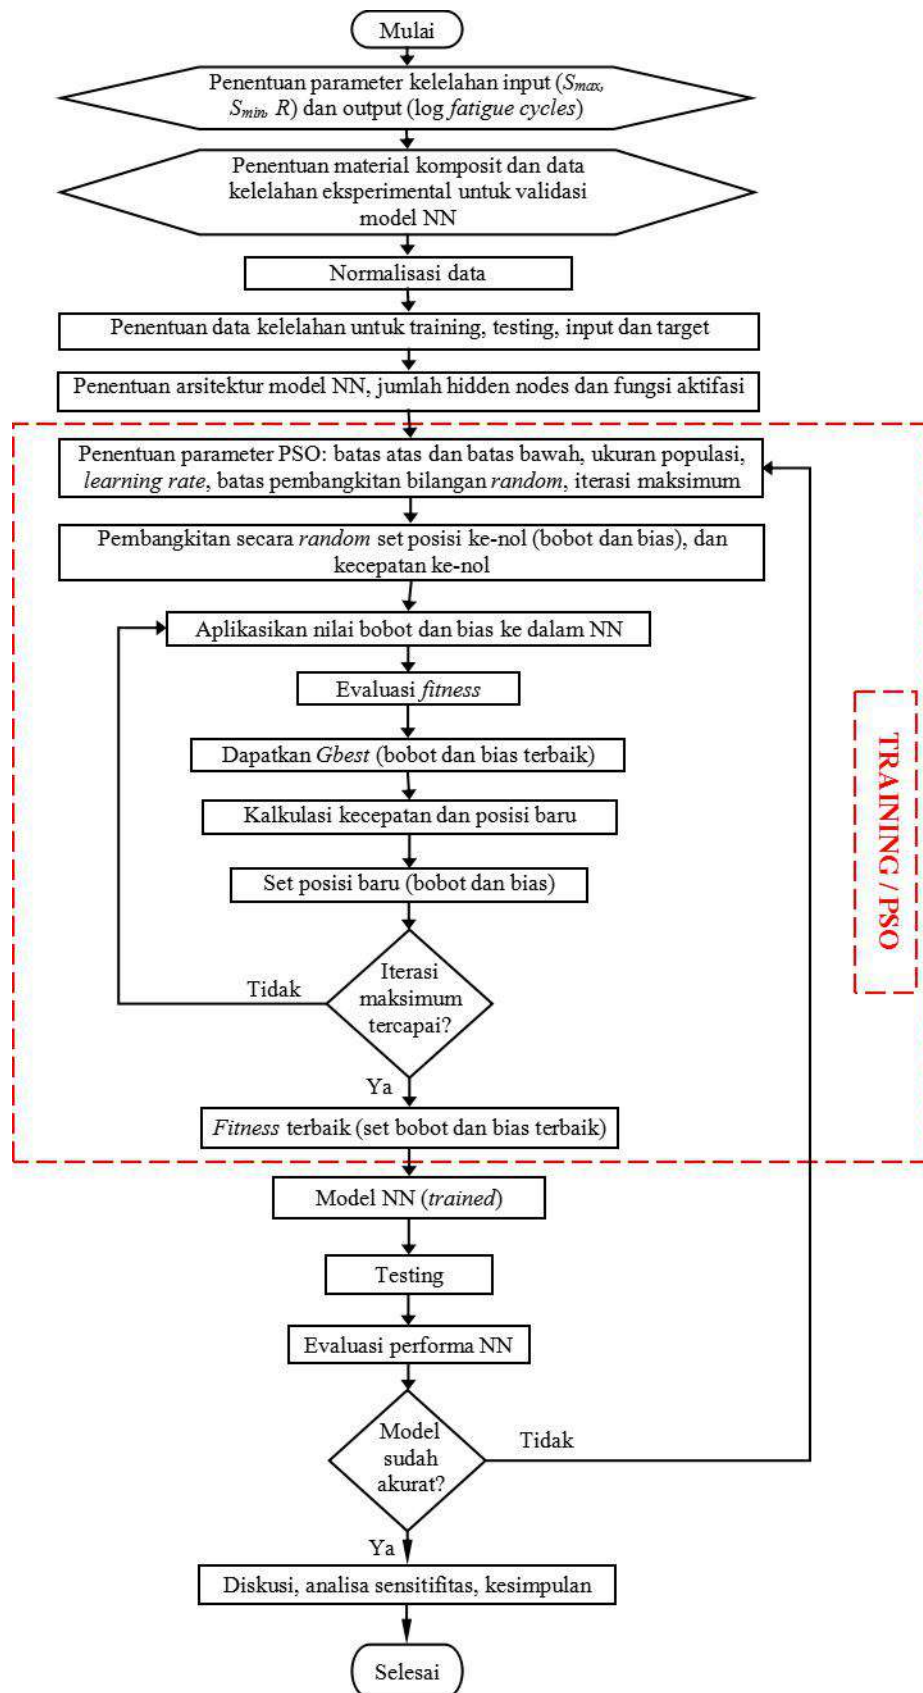
Diagram alir pemodelan NN tersebut terdiri dari tiga, yaitu *hybrid* MLP-GA, *hybrid* MLP-DE dan *hybrid* MLP-PSO, secara berurutan ditunjukkan pada Gambar 3.1, 3.2 dan 3.3.



Gambar 3.1. Diagram alir pemodelan *hybrid* MLP-GA



Gambar 3.2. Diagram alir pemodelan *hybrid* MLP-DE



Gambar 3.3. Diagram alir pemodelan *hybrid* MLP-PSO

3.2 Parameter Kelelahan

Parameter kelelahan yang digunakan untuk input NN pada penelitian ini adalah nilai *stress ratio* (R), tegangan maksimum (S_{max}), dan tegangan minimum (S_{min}). Output NN adalah *log fatigue cycles*. Pemilihan ini mengacu pada penelitian yang dilakukan oleh Hidayat dkk. (2009).

3.3 Material dan Data Kelelahan Untuk Validasi Model

Validasi model NN menggunakan dua material komposit yang berbeda. Material pertama yang digunakan adalah dengan kode MD-QQ1-EP2-S, dengan serat penguat (*fiber*) jenis *E-glass* dengan *fiber volume fraction* (v_f) rata-rata 53% dan matrix menggunakan resin jenis *epoxy* (*thermoset*). Serat penguat disusun membentuk laminat dengan ketebalan rata-rata 4.09 mm dengan susunan lamina $[\pm 45/0_2]_s$. Fabrikasi laminat menggunakan metode *vacum assisted resin transfer molding* (VARTM), dengan *curing* selama 24 jam pada temperature 20°C dan dilanjutkan dengan *post-curing* selama 8 jam pada temperature 70°C. Sampel untuk pengujian diambil dengan lebar 25 mm dan *gage length* 100 mm. Dari pengujian tarik (*tensile test*) dengan arah longitudinal didapatkan *ultimate tensile stress* rata-rata sebesar 869 MPa, *ultimate tensile strain* rata-rata 2.63%, modulus elastisitas tarik (E) rata-rata sebesar 33 GPa, *minimum compression stress* rata-rata -690 MPa dan *minimum compression strain* rata-rata -2.07%. Untuk menjaga *temperature* kupon agar tidak terjadi *over-heating*, pengujian kelelahan dilakukan dengan frekwensi 1-10 Hz, dan dengan dihembuskan udara (*fresh air*). (Mandell dkk., 2016). Deskripsi material tersebut secara ringkas ditunjukkan pada Tabel 3.1.

Material kedua yang digunakan untuk validasi model NN adalah dengan kode MD-DD16-UP2, dengan serat penguat (*fiber*) jenis *E-glass* dengan *fiber volume fraction* (v_f) rata-rata 33% dan matrix menggunakan resin jenis *polyester* (*thermoset*). Serat penguat disusun membentuk laminat dengan ketebalan rata-rata 4.62 mm dengan susunan lamina $[90/0/\pm 45/0]_s$. Fabrikasi laminat menggunakan metode *resin transfer molding* (RTM), dengan *curing* selama 24 jam pada temperature 20°C dan dilanjutkan dengan *post-curing* selama 2 jam pada temperature 60°C. Sampel untuk pengujian diambil dengan lebar 25 mm dan

gage length 100 mm. Dari pengujian tarik (*tensile test*) dengan arah longitudinal didapatkan *ultimate tensile stress* rata-rata sebesar 602.85 MPa, modulus elastisitas tarik (E) rata-rata sebesar 18.2 GPa dan *minimum compression stress* rata-rata -401.2 MPa. Untuk menjaga *temperature* kupon agar tidak terjadi *over-heating*, pengujian kelelahan dilakukan dengan frekwensi 0.1-15 Hz, dan dengan dihembuskan udara (*fresh air*) (Mandell, dkk., 2016). Deskripsi material tersebut secara ringkas ditunjukkan pada Tabel 3.2.

Tabel 3.1. Data Material Komposit *E-glass/Epoxy* MD-QQ1-EP2-S (Samborsky dkk., 2016)

Properties	Nilai
Serat Penguat	E-glass
Matrix (Resin)	Epoxy
Lay Up	[±45/0 ₂] _s
Metode Fabrikasi	VARTM
Cure & Post Cure	24h/20°C, 8h/70°C
Tebal rata-rata, mm	4.09
Fiber volume fraction (v_f) rata-rata, %	52
Maximum Stress rata-rata, MPa	869
Maximum tensile strain rata-rata, %	2.63
Modulus elastisitas tarik rata-rata (E), GPa	33
Minimum compression stress rata-rata, MPa	-690
Minimum compression strain rata-rata, %	-2.07

Tabel 3.2. Data Material Komposit *E-glass/polyester* MD-DD16-UP2 (Samborsky dkk., 2016)

Properties	Nilai
Serat Penguat	E-glass
Matrix (Resin)	Polyester
Lay Up	[90/0/±45/0] _s
Metode Fabrikasi	RTM
Cure & Post Cure	24h/20°C, 2h/60°C
Tebal rata-rata, mm	4.62
Fiber volume fraction (v_f) rata-rata, %	33
Maximum Stress rata-rata, MPa	602.85
Modulus elastisitas tarik rata-rata (E), GPa	18.2
Minimum compression stress rata-rata, MPa	-401.2

Data kelelahan yang digunakan untuk validasi model NN harus dengan informasi yang diperlukan untuk keperluan analisa dan pengujian model, yaitu *stress ratio* (R) tegangan maksimum (S_{max}), tegangan minimum (S_{min}) dan umur kelelahan (*log cycles to failure*), dan harus terdistribusi dalam empat daerah yang ditunjukkan dalam CLD, yaitu daerah T-T, T-C, C-T, dan C-C.

Data kelelahan yang digunakan untuk validasi model NN dalam penelitian ini adalah data sekunder dari laporan Sandia National Laboratories / Montana State University / Department of Energy (SNL/MSU/DOE) (Samborsky dkk., 2016).

Parameter kelelahan yang digunakan adalah nilai *stress ratio* (R), tegangan maksimum (S_{max}), dan tegangan minimum (S_{min}) yang digunakan sebagai *input set*, sedangkan outputnya adalah log siklus kelelahan ($\log N$) dari masing-masing data. Nilai umur kelelahan yang digunakan adalah nilai rata-rata dari setiap nilai *stress ratio* (R). Semua data dinormalisasi pada rentang (-1,1), dengan menggunakan persamaan 3.1

$$X_n = \frac{2X - X_{max} - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

dimana: X_n adalah nilai variabel input yang ternormalisasi (R , S_{max} dan S_{min}) atau variabel output (*log fatigue cycles*), X adalah data yang tidak dinormalisasi, X_{min} , X_{max} secara berurutan adalah nilai minimum dan maksimum dari tiap variabel.

3.4 Penentuan Data Kelelahan Untuk Training dan Testing

Kumpulan data hasil eksperimen yang sudah ditentukan dibagi menjadi dua grup yaitu data untuk *training* dan *testing*.

a. Data untuk training

Data yang digunakan untuk training adalah data kelelahan dengan nilai umur kelelahan rata-rata. Digunakan data kelelahan pada *stress ratio* (R) kombinasi yang mewakili tiga daerah pembebanan sesuai dengan CLD, yaitu tegangan tarik-tarik (T-T/T-T), tegangan tarik-kompresi (T-T/T-C) dan tegangan kompresi-kompresi (C-C/C-C). Dari ketiga kombinasi data set kondisi pembebanan tersebut akan

diketahui kombinasi mana yang menghasilkan akurasi NN yang paling tinggi. Pemilihan kombinasi level stress ratio tersebut mengacu pada penelitian dari Hidayat dkk. (2009) yang melakukan training dengan material *E-Glass/Epoxy*, [$\pm 45/0_4/\pm 45/$], dengan data training set pada R 0.1 dan 10 digunakan untuk memprediksi umur kelelahan pada material yang sama dengan R yang berbeda yaitu 0.5, -0.5, -1 dan 10. Nilai hasil prediksi dibandingkan data eksperimen menunjukkan angka akurasi yang tinggi.

Nilai target yang digunakan adalah nilai log *fatigue cycles* dari data eksperimental dari tiap-tiap *stress ratio*.


b. Data untuk testing

Data yang digunakan untuk testing adalah data kelelahan dengan nilai umur kelelahan rata-rata. Digunakan data kelelahan pada *stress ratio* (R) kombinasi yang tersebar pada tiga daerah pembebanan sesuai dengan CLD, yaitu tegangan tarik-tarik (T-T/T-T), tegangan tarik-kompresi (T-T/T-C) dan tegangan kompresi-kompresi (C-C/C-C).

Nilai target yang digunakan adalah nilai log *fatigue cycles* dari data eksperimental dari tiap-tiap *stress ratio*.

3.5 Pemodelan NN

Model arsitektur NN adalah *multilayers perceptrons* (MLP) yang terdiri dari sebuah input layer, sebuah *hidden layer* yang tersusun dari beberapa *hidden nodes* dan sebuah output layer, seperti yang ditunjukkan pada Gambar 2.18, yang ditampilkan ulang seperti di bawah ini .



Gambar 2.18. Arsitektur MLP dengan satu *hidden layer* dan single output (Hidayat dkk., 2009)

Jumlah *hidden nodes* yang digunakan dalam penelitian ini adalah sebanyak 6 hingga 30, dari variasi *hidden nodes* tersebut akan diketahui jumlah *hidden nodes* berapa yang menghasilkan akurasi NN yang paling tinggi.

Fungsi aktivasi $\tau(\cdot)$ yang digunakan adalah *logistic-sigmoid* seperti yang ditunjukkan pada persamaan 3.2. Variabel n adalah nilai keluaran sinyal dari masing-masing *hidden nodes* yang berdekatan dengan *input layer*.

$$\tau(n) = \frac{1}{(1 + e^{-n})} \quad (3.2)$$

3.6 Training NN

Proses training menggunakan data kelelahan pada R kombinasi yang mewakili tiga daerah pembebanan sesuai dengan CLD, yaitu tegangan tarik-tarik (T-T/T-T), tegangan tarik-kompresi (T-T/T-C) dan tegangan kompresi-kompresi (C-C/C-C). Data yang digunakan untuk material MD-QQ1-EP2-S (material 1) maupun MD-DD16-UP2 (material 2) adalah $R = 0.1$ (tarik-tarik), $R = 0.5$ (tarik-tarik), $R = -1$ (tarik-tekan) dan $R = 10$ (tekan-tekan). yaitu pada pada $R =$

0.1 (T-T), $R = 0.5$ (T-T), $R = -1$ (T-C) dan $R = 10$ (C-C). Kombinasi *stress ratio* (R) yang digunakan pada proses training ditunjukkan pada Tabel 3.3 dan 3.4 secara berurutan untuk material 1 dan 2.

Tabel 3.3. Tabel Rencana Penelitian Untuk Material 1

Algoritma Learning	Sudut Orientasi	Training Set (R)	Testing Set (R)	Iterasi Maksimum
Genetic Algorithm (GA)	On-axis	0.1 dan 0.5	-0.5, -1, -2, 10	50, 100, 200
	On-axis	0.1 dan -1	0.5, -0.5, -2, 10	50, 100, 200
	On-axis	0.1 dan 10	0.5, -0.5, -1, -2	50, 100, 200
Differential Evolution (DE)	On-axis	0.1 dan 0.5	-0.5, -1, -2, 10	50, 100, 200
	On-axis	0.1 dan -1	0.5, -0.5, -2, 10	50, 100, 200
	On-axis	0.1 dan 10	0.5, -0.5, -1, -2	50, 100, 200
Particle Swarm Optimization (PSO)	On-axis	0.1 dan 0.5	-0.5, -1, -2, 10	50, 100, 200
	On-axis	0.1 dan -1	0.5, -0.5, -2, 10	50, 100, 200
	On-axis	0.1 dan 10	0.5, -0.5, -1, -2	50, 100, 200

Tabel 3.4. Tabel Rencana Penelitian Untuk Material 2

Algoritma Learning	Sudut Orientasi	Training Set (R)	Testing Set (R)	Iterasi Maksimum
Genetic Algorithm (GA)	On-axis	0.1 dan 0.5	0.7, 0.8, 0.9, -0.5, -1, -2, 10	50, 100, 200
	On-axis	0.1 dan -1	0.5, 0.7, 0.8, 0.9, -0.5, -2, 10	50, 100, 200
	On-axis	0.1 dan 10	0.5, 0.7, 0.8, 0.9, -0.5, -1, -2	50, 100, 200
Differential Evolution (DE)	On-axis	0.1 dan 0.5	0.7, 0.8, 0.9, -0.5, -1, -2, 10	50, 100, 200
	On-axis	0.1 dan -1	0.5, 0.7, 0.8, 0.9, -0.5, -2, 10	50, 100, 200
	On-axis	0.1 dan 10	0.5, 0.7, 0.8, 0.9, -0.5, -1, -2	50, 100, 200
Particle Swarm Optimization (PSO)	On-axis	0.1 dan 0.5	0.7, 0.8, 0.9, -0.5, -1, -2, 10	50, 100, 200
	On-axis	0.1 dan -1	0.5, 0.7, 0.8, 0.9, -0.5, -2, 10	50, 100, 200
	On-axis	0.1 dan 10	0.5, 0.7, 0.8, 0.9, -0.5, -1, -2	50, 100, 200

Proses training pada MLP dilakukan dengan metode *supervised learning*, yaitu nilai hasil prediksi NN dibandingkan dengan data target berupa nilai data eksperimental, jika hasil prediksi berbeda dengan nilai target maka network menghasilkan error, berdasarkan error tersebut kemudian network melakukan

penyesuaian ulang terhadap bobot (*weight*) dan bias yang sudah ada, proses tersebut diulang-ulang terus sehingga menghasilkan output dengan nilai *error* yang serendah mungkin. Penyesuaian nilai bobot dan bias dilakukan dengan metode optimasi algoritma genetik (GA), *particle swarm optimization* (PSO) dan *differential evolution* (DE).

3.7 Akurasi Model NN

Tingkat akurasi dari nilai prediksi umur kelelahan (output *testing*) untuk semua data diukur dengan *mean squared error* (*MSE*) sesuai dengan persamaan 3.3, semakin rendah nilai *MSE* menunjukkan tingkat akurasi NN yang semakin baik:

$$MSE = \frac{1}{M} \sum_{i=1}^M (y_i - \hat{y}_i)^2 \quad (3.3)$$

Dimana M adalah banyaknya *data points* dari *testing data sets*, y_i adalah nilai umur kelelahan (*log fatigue cycles*) hasil eksperimental dan \hat{y}_i adalah nilai umur kelelahan (*log fatigue cycles*) prediksi NN.


Tingkat akurasi dari nilai prediksi umur kelelahan untuk setiap tingkat *stress ratio* (R) diukur dengan *coefficient of determination* (R^2) sesuai dengan persamaan 3.3, semakin tinggi nilai R^2 menunjukkan tingkat akurasi NN yang semakin baik:

$$R^2 = 1 - \frac{\sum_{i=1}^M (y_i - \hat{y}_i)^2}{\sum_{i=1}^M (y_i - \bar{y})^2} \quad (3.4)$$

Dimana M adalah banyaknya *data points* dari *testing data sets* pada nilai *stress ratio* tertentu, y_i adalah nilai umur kelelahan (*log fatigue cycles*) hasil eksperimental, \bar{y} adalah rata-rata nilai umur kelelahan (*log fatigue cycles*) experimental pada nilai *stress ratio* tertentu, dan \hat{y}_i adalah nilai umur kelelahan (*log fatigue cycles*) prediksi NN. Suatu model NN memiliki kemampuan untuk

generalisasi dengan akurasi yang tinggi jika memiliki nilai $R^2 \geq 0.9$ (Zhang dkk., 2003).

Akurasi juga dihitung berdasarkan banyaknya prediksi NN yang bisa digunakan. Kriteria “bisa digunakan” adalah jika hasil prediksi NN nilainya berada di dalam populasi distribusi log-normal data hasil eksperimen. Populasi distribusi log-normal data hasil eksperimen dan plot data prediksi NN diilustrasikan pada Gambar 3.4.



Gambar 3.4. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN. Kurva dibangun menggunakan metode distribusi log-normal. P = probabilitas kegagalan.

Sehingga rumus akurasi ditunjukkan pada persamaan 3.5.

$$\text{Akurasi} = \frac{n_A}{n_A + n_B} * 100\% \quad (3.5)$$

Dimana:

- n : Banyaknya data
- A : Data prediksi NN yang diterima
- B : Data prediksi NN yang ditolak

Kurva P - S - N pada Gambar 3.4 dibangun berdasarkan data kelelahan hasil eksperimen. Nilai logaritmik dari umur kelelahan ($\log(N)$) diasumsikan

terdistribusi normal, dan *variance* $\log(N)$ adalah konstan pada semua range variabel independen (S_{max}), dengan demikian *scatter* $\log(N)$ dianggap sama mulai dari S_{max} level rendah hingga tinggi. (ASTM E-739-91, 2004, Lee, 2005).

Untuk mendapatkan kurva P - S - N , $\log(N)$ dianggap sebagai *dependent variable* (diletakkan pada sumbu Y) dan S_{max} dianggap sebagai *independent variable* (diletakkan pada sumbu X). Hubungan antara $\log(N)$ dan S_{max} dianggap sebagai hubungan yang linier, seperti yang ditunjukkan pada persamaan 3.6 (ASTM E-739-91, 2004, Lee, 2005).

$$\log(N) = A + B.S_{max} \quad (3.6)$$

atau

$$Y = A + B.X \quad (3.7)$$

Persamaan 3.7 diestimasi dengan metode *least-square* seperti persamaan 3.8, dimana \hat{Y} , \hat{A} dan \hat{B} secara berurutan merupakan estimator dari Y , A dan B . Nilai \hat{Y} merupakan *mean* ($P, 0.50$) seperti pada Gambar 3.4.

$$\hat{Y} = \hat{A} + \hat{B}.X \quad (3.8)$$

Konstanta \hat{B} didapatkan dengan menggunakan rumus 3.9.

$$\hat{B} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (3.9)$$

Dimana n adalah banyaknya data eksperimen, \bar{X} dan \bar{Y} secara berurutan adalah nilai rata-rata dari X dan Y . Konstanta \hat{A} didapatkan dengan rumus 3.10.

$$\hat{A} = \bar{Y} - \hat{B}.\bar{X} \quad (3.10)$$

Nilai *variance* (s^2) didapatkan dengan rumus 3.11.

$$s^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n-2} \quad (3.11)$$

Garis $(P, 0.025)$ dan $(P, 0.975)$ seperti pada Gambar 3.4 didapatkan dengan rumus 3.12 dan 3.13.

$$P, 0.025 = P, 0.50 - 1.96s \quad (3.12)$$

$$P, 0.975 = P, 0.50 + 1.96s \quad (3.13)$$

Angka 1.96 pada persamaan 3.12 dan 3.13 didapatkan dari tabel distribusi normal (*two-tails*), yaitu nilai z pada tingkat kepercayaan 95%.

3.8 Analisa Sensitivitas

Analisa sensitifitas bertujuan untuk mengetahui tingkat pengaruh parameter dalam pemodelan NN, yaitu training set, iterasi maksimum dan jumlah *hidden nodes (net size)* terhadap akurasi prediksi NN dalam MSE. Selain itu interaksi antara parameter tersebut juga bisa diketahui. Metode pengujian yang digunakan adalah ANOVA 3-Faktor. Proses perhitungan menggunakan *software* Minitab.

3.9 Realisasi

Pseudocodes dari pemodelan NN ditulis dengan MATLAB R2016b, dengan perangkat keras Lenovo Z40 dengan OS Windows 8.1, prosesor AMD 10-7300 Radeon R6 dan RAM 4 GB.

(Halaman ini sengaja dikosongkan)

BAB 4

HASIL SIMULASI DAN PEMBAHASAN

4.1. Parameter NN, GA, DE dan PSO

Hasil simulasi model NN dengan algoritma training GA, DE dan PSO ditampilkan pada bab ini. Parameter NN yang digunakan ditunjukkan pada Tabel 4.1. Parameter GA, DE dan PSO dengan berurutan ditunjukkan pada Tabel 4.2, 4.3 dan 4.4.

Tabel 4.1. Parameter Yang Digunakan Pada Pemodelan NN

Parameter NN	Nilai
Jumlah <i>hidden layer</i>	1
Jumlah <i>hidden nodes</i> dalam percobaan	6 - 30
<i>Data normalization range</i>	(-1,1)
<i>Actifation function</i>	<i>Logistic-sigmoid</i>

Tabel 4.2. Parameter GA Yang Digunakan Pada Pemodelan NN

Parameter GA	Nilai
<i>Range</i> nilai populasi awal	rand(-1,1)
<i>Range</i> nilai populasi	(-1,1)
Ukuran populasi	100
Jumlah kromosom	Jumlah bobot dan bias
Probabilitas <i>crossover</i>	0.80
<i>Mutation rate</i>	0.40
Metode seleksi kromosom	<i>Roulette wheel</i>
Iterasi maksimum	Variasi (50,100, 200)

Tabel 4.3. Parameter DE Yang Digunakan Pada Pemodelan NN

Parameter DE	Nilai
<i>Range</i> populasi awal	rand(-1,1)
<i>Range</i> nilai populasi	(-1,1)
Ukuran populasi	100
Jumlah kromosom	Jumlah bobot dan bias
<i>Crossover rate</i>	0.9
<i>Mutation rate</i>	0.2
<i>Handling of boundary violation</i>	<i>Random reinitialization</i>
Iterasi maksimum	Variasi (50,100, 200)

Tabel 4.4. Parameter PSO Yang Digunakan Pada Pemodelan NN

Parameter PSO	Nilai
<i>Range</i> posisi awal	rand(-1,1)
Kecepatan awal	<i>Zeros</i>
<i>Range</i> nilai populasi	(-1,1)
Ukuran populasi	100
Jumlah kromosom	Jumlah bobot dan bias
r_1, r_2	rand(0.1)
c_1, c_2	0.5
<i>Inertia of velocity</i>	0.4 - 0.9
<i>Avoiding velocity explosion</i>	<i>Velocity bound</i>
<i>Correction of boundary violation</i>	<i>Random reposition</i>
Iterasi maksimum	Variasi (50,100, 200)

4.2. Pemilihan Arsitektur NN Berdasarkan Jumlah Hidden Nodes Yang Optimal

Permasalahan yang umum di dalam pemodelan dengan NN adalah generalisasi. Sebuah model NN memiliki kemampuan generalisasi yang bagus jika pada training mampu menghasilkan error yang rendah demikian juga pada testing yang menggunakan data input yang sama sekali berbeda dengan training. Sebaliknya jika pada training mampu menghasilkan error yang rendah namun pada testing menghasilkan error yang tinggi maka dikatakan kemampuan generalisasinya rendah.

Generalisasi dipengaruhi oleh tiga faktor, antara lain (Haykin, 2009):


- (1) Ukuran atau banyaknya contoh data yang digunakan untuk training serta seberapa tingkat kualitas contoh data mewakili permasalahan yang sesungguhnya.
- (2) Arsitektur neural network
- (3) Kompleksitas permasalahan system yang akan dimodelkan.

Faktor no (3) di atas tidak bisa dikendalikan, sehingga hanya faktor no (1) dan (2) yang bisa dikendalikan (Haykin, 2009). Faktor arsitektur NN bisa disiasati dengan menentukan beberapa arsitektur NN kemudian dipilih arsitektur yang terbaik. Pada studi ini ukuran contoh data sudah ditentukan yaitu dengan *limited data* seperti yang sudah dijelaskan sebelumnya.

Ketika optimasi bobot dan bias dari NN menggunakan algoritma

metaheuristik, situasinya bisa menjadi semakin rumit. Sumber dari hasil yang kurang menentu bisa disebabkan oleh populasi awal dengan bilangan random dan juga perbaikan generasi yang melibatkan penggunaan bilangan random.

Masalah lain yang bisa menyebabkan rendahnya generalisasi adalah *overtraining*. Pada saat training setiap penambahan iterasi (*epoch*) selalu menghasilkan akurasi training yang lebih baik dan semakin panjang iterasi menghasilkan akurasi training yang lebih baik. *Overtraining* diilustrasikan pada Gambar 4.1. Masalah generalisasi bisa muncul karena akurasi training yang terlalu tinggi sehingga network akan selalu mengingat training, ketika data baru digunakan pada testing maka respon terhadap data baru tersebut berkurang (Haykin, 2009 and Priddy dkk., 2005).



Gambar 4.1. Ilustrasi *overtraining* (kurva warna hijau)

Untuk menghadapi permasalahan generalisasi tersebut maka pada studi ini menggunakan 25 model MLP yang berbeda dengan jumlah hidden nodes yang bervariasi dari 6 hingga 30. Selanjutnya untuk mengantisipasi terjadinya *overtraining* digunakan iterasi maksimum 50, 100 dan 200. Dengan melakukan 30 kali pengulangan secara independen selanjutnya masing-masing prediksi umur kelelahan diambil nilai rata-ratanya dan dibandingkan dengan umur kelelahan dari data eksperimental untuk mengetahui akurasinya.

4.3. Simulasi Dengan Hybrid MLP-GA

4.3.1. Hasil Simulasi Dengan Material 1

4.3.1.1. Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental

Konsistensi prediksi model NN terhadap data kelelahan eksperimental ditunjukkan dengan dua metode, pertama dengan membandingkan *trend* berdasarkan *S-N curve* pada tiap *stress ratio*, kedua dengan melihat tingkat korelasi antara prediksi model NN terhadap data kelelahan eksperimental.

Tingkat korelasi diquantifikasi dengan nilai *coeffocoent of determination* (r^2) yang merupakan nilai pangkat dua dari *Pearson's linear correlation coefficient* (r). Dikatakan konsisten jika nilai r^2 adalah positif dan bernilai lebih besar atau sama dengan 0.25 atau nilai r yang bernilai positif dan lebih besar atau sama dengan 0.5 (Cohen, 1988). Nilai r dihitung dengan persamaan 4.1 (Bhattacharya dkk., 1977). Selain itu nilai r secara statistik harus memiliki *t-value* yang signifikan yang dibuktikan dengan *P-value* kurang dari 0.025 (*two-tailed t-distribution* dengan $\alpha = 0.05$). Dimana *t-value* dihitung dengan persamaan 4.2 (Bhattacharya, G.K, dkk, 1977).

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\left[\sum_{i=1}^n (X_i - \bar{X})^2 \right] \left[\sum_{i=1}^n (Y_i - \bar{Y})^2 \right]}} \quad (4.1)$$

$$t\text{-value} = \frac{r \cdot \sqrt{n-2}}{\sqrt{1-r^2}} \quad \text{d.f} = n-2 \quad (4.2)$$

Dimana:

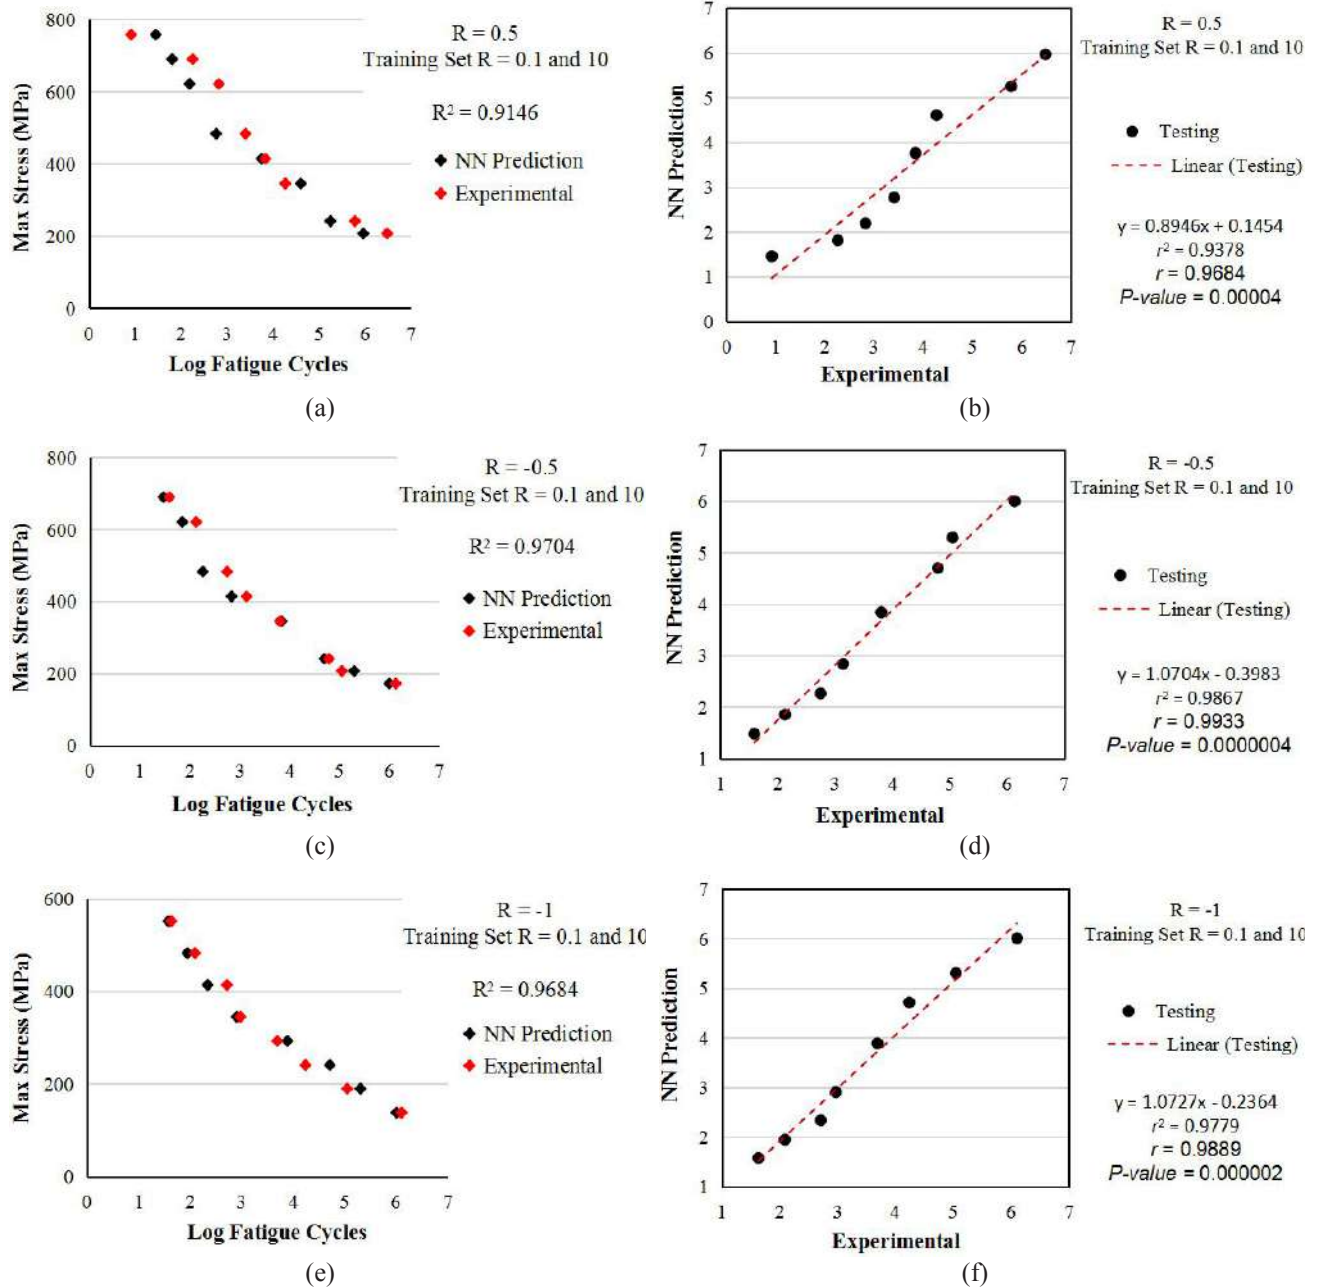
- n : Banyaknya data
- X : Nilai *log fatigue cycles* prediksi NN atau nilai variabel X
- Y : Nilai *log fatigue cycles* eksperimental atau nilai variabel Y


P-value didapatkan dengan menggunakan fungsi excel yang sudah sangat umum digunakan yaitu =*TDIST*(*t-value*,*d.f*,1).

Kedua metode tersebut juga digunakan untuk memperlihatkan konsistensi hasil

prediksi model NN pada material 2 dan metode optimasi yang lain.

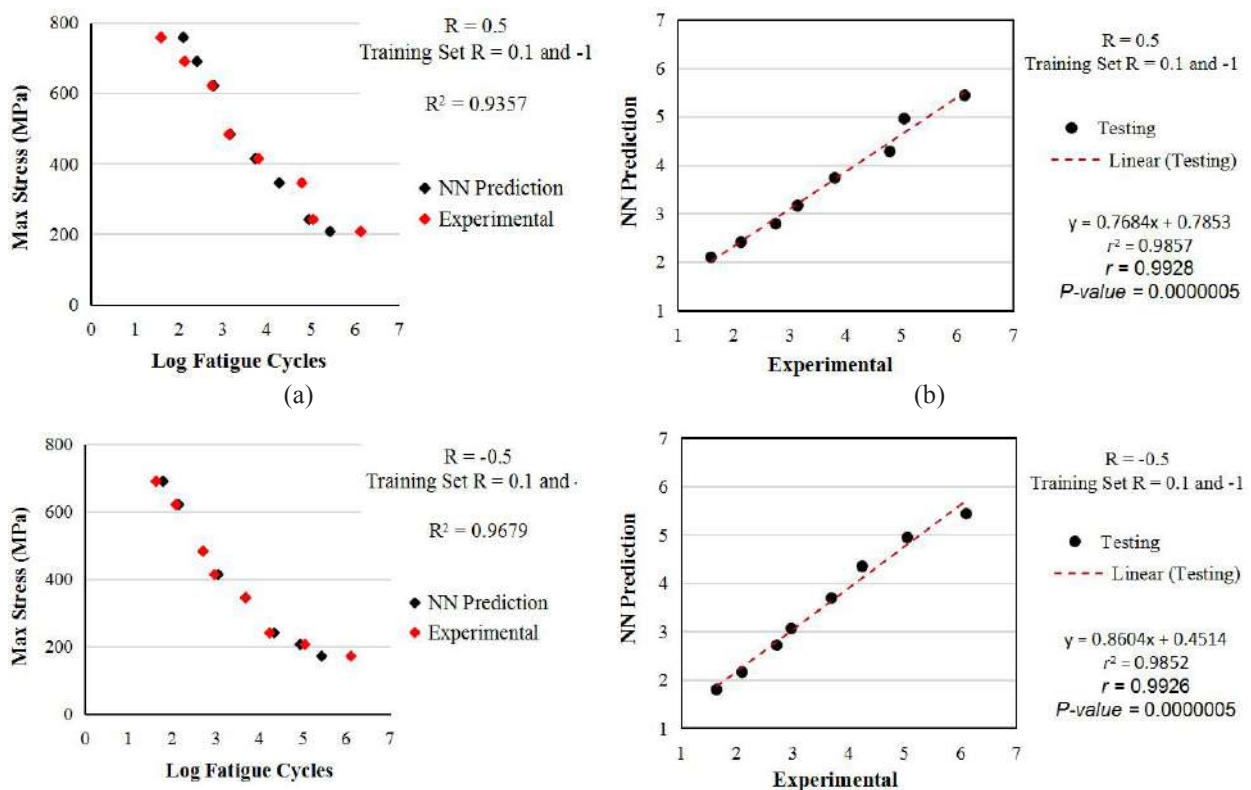
Hasil simulasi dengan akurasi testing terbaik ditunjukkan pada Gambar 4.2 yang merupakan hasil prediksi model NN dengan training set 3, iterasi maksimum 200 dan jumlah hidden nodes = 27. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.

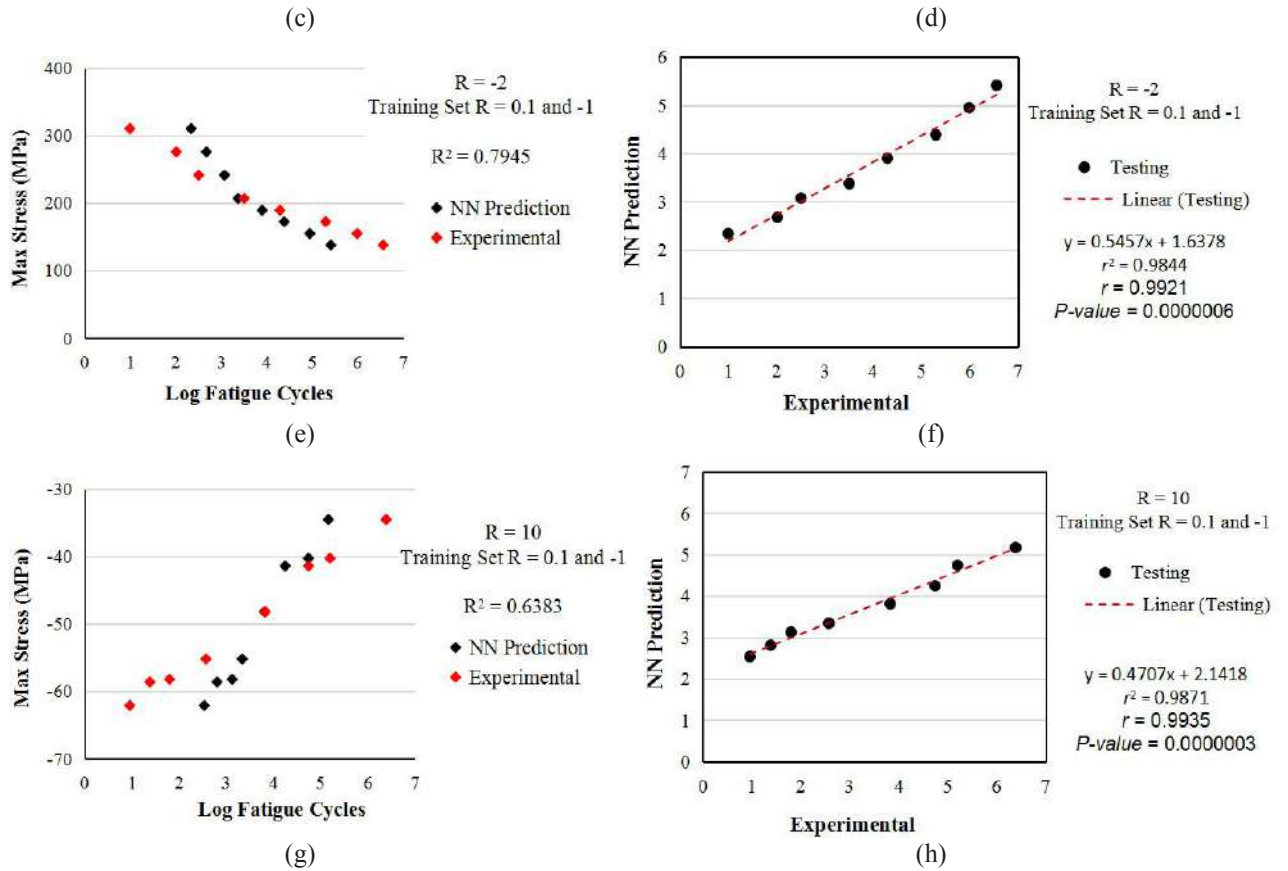




Gambar 4.2. *S-N curve* dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 1, dengan training Set 3, iterasi maksimum 200 dan jumlah hidden nodes = 27. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = -0.5$. (d) Korelasi pada $R = -0.5$. (e) *S-N curve* $R = -1$. (f) Korelasi pada $R = -1$. (g) *S-N curve* $R = -2$. (h) Korelasi pada $R = -2$

Hasil simulasi dengan akurasi testing paling rendah ditunjukkan pada Gambar 4.3 yang merupakan hasil prediksi model NN dengan training set 2, iterasi maksimum 50 dan jumlah hidden nodes = 8. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.







Gambar 4.3. *S-N curve* dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 1, dengan training Set 2, iterasi maksimum 50 dan jumlah hidden nodes = 8. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = -0.5$. (d) Korelasi pada $R = -0.5$. (e) *S-N curve* $R = -2$. (f) Korelasi pada $R = -2$. (g) *S-N curve* $R = 10$. (h) Korelasi pada $R = 10$

4.3.1.2. Akurasi Prediksi Model NN

Akurasi prediksi model NN dalam bentuk plot nilai *MSE* (maksimum, rata-rata, dan minimum) dan distribusi normal (dengan $\alpha = 0.05$) disajikan pada Gambar 4.4. Plot nilai *MSE* rata-rata dan *confidence interval* (dengan $\alpha = 0.05$) dari model NN yang rendah disajikan pada Gambar 4.5. Dengan melihat nilai *MSE* rata-rata, distribusi normal dan *confidence interval*, terlihat model NN dengan training set 3 dengan iterasi maksimum 200 menunjukkan akurasi yang paling tinggi. Sementara itu model NN dengan training set 2 dengan iterasi maksimum 50 menunjukkan akurasi yang paling rendah. Untuk melihat nilai *MSE* (maksimum, rata-rata (*average*), dan minimum) dari masing-masing model NN, bisa dilihat pada Tabel 4.5.



Gambar 4.4. Plot nilai *MSE* (*average*, *minimum* dan *maximum*) dan *error bar* yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-GA untuk material 1. Deskripsi dari Model No. dan nilai *MSE* tersebut ditunjukkan pada Tabel 4.5




Gambar 4.5. Plot nilai *MSE* dan *error bar* yang menunjukkan *confidence interval* dengan $\alpha = 0.05$, dari akurasi MLP-GA untuk material 1, dengan training set 1 dan 3.

Tabel 4.5. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.4 Dan 4.5 Dan Nilai *MSE* (*Average*, *Minimum* dan *Maximum*) Pada Masing-masing Model (MLP-GA)

Model No.	Training Set	Jumlah Hidden Nodes	Iterasi Maksimum	<i>MSE</i> (<i>average</i>)	<i>MSE</i> Min.	<i>MSE</i> Max.
1	Set 1	6-30	50	0.2784	0.1954	0.4248
2	Set 1	6-30	100	0.2649	0.1683	0.4076
3	Set 1	6-30	200	0.2413	0.1698	0.3422
4	Set 2	6-30	50	0.3571	0.2677	0.5121
5	Set 2	6-30	100	0.3449	0.2509	0.4448
6	Set 2	6-30	200	0.3208	0.2364	0.4126
7	Set 3	6-30	50	0.2178	0.1538	0.4134
8	Set 3	6-30	100	0.2074	0.1582	0.3214
9	Set 3	6-30	200	0.2042	0.1533	0.2939


Akurasi model NN yang diukur dalam *MSE* dan R^2 untuk masing-masing *stress ratio* dengan training set 3 dan iterasi maksimum 200 dengan jumlah hidden nodes 6 hingga 30 disajikan pada Tabel 4.6. Dalam hal akurasi (nilai R^2) untuk masing-masing *stress ratio*, nilai maksimum, rata-rata dan minimum disajikan dengan plot pada tiap-tiap *stress ratio* (R) pada Gambar 4.6. Nilai maksimum, rata-rata dan minimum tersebut berdasarkan nilai R^2 dari model dengan hidden nodes 6 hingga 30.



Gambar 4.6. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (*average*) dan minimum) untuk tiap-tiap *stress ratio* (R) dari MLP-GA dengan jumlah *hidden nodes* 6 hingga 30 untuk material 1, dengan training set 3 dan iterasi maksimum 200

Tabel 4.6. Akurasi Prediksi Model MLP-GA Dengan Nilai MSE dan R^2 Untuk Material 1 Dengan Training Set 3, Iterasi Maksimum 200 Dan Jumlah *Hidden Nodes* 6 Hingga 30 (model no. 9)

Jumlah Hidden Nodes	MSE	Coefficient of Determination R^2			
		$R = 0.5$	$R = -0.5$	$R = -1$	$R = -2$
6	0.2939	0.8711	0.9532	0.9615	0.8184
7	0.2878	0.8820	0.9548	0.9638	0.8141
8	0.2212	0.8890	0.9691	0.9746	0.8758
9	0.2184	0.8988	0.9586	0.9695	0.8748
10	0.2169	0.8913	0.9756	0.9746	0.8693
11	0.1976	0.9102	0.9652	0.9735	0.8830
12	0.1969	0.9151	0.9599	0.9670	0.8868
13	0.2108	0.9073	0.9667	0.9715	0.8704
14	0.2189	0.9125	0.9457	0.9548	0.8793
15	0.1823	0.9223	0.9665	0.9714	0.8910
16	0.2119	0.9132	0.9591	0.9658	0.8721
17	0.1738	0.9128	0.9682	0.9727	0.9071
18	0.1725	0.9128	0.9699	0.9754	0.9058
19	0.2403	0.9236	0.9339	0.9382	0.8621
20	0.2143	0.9198	0.9484	0.9529	0.8779
21	0.1859	0.9183	0.9539	0.9594	0.9049
22	0.2030	0.9196	0.9546	0.9645	0.8807
23	0.1859	0.9271	0.9580	0.9604	0.8946
24	0.1911	0.9104	0.9657	0.9696	0.8922
25	0.1815	0.9224	0.9666	0.9688	0.8933
26	0.1976	0.9178	0.9522	0.9555	0.8951
27	0.1533	0.9146	0.9704	0.9684	0.9304
28	0.1804	0.9136	0.9624	0.9663	0.9061
29	0.1866	0.9245	0.9567	0.9603	0.8967
30	0.1823	0.9181	0.9627	0.9634	0.9015




Gambar 4.7. Plot nilai MSE testing terhadap jumlah *hidden nodes* 6 hingga 30 untuk material 1, dengan training set 3 dan iterasi maksimum 200

Gambar 4.7 adalah menggambarkan plot hubungan antara *MSE* testing terhadap jumlah hidden nodes untuk training set 3 dan iterasi maksimum 200. Dari plot tersebut menunjukkan korelasi yang negatif antara *MSE* testing dan jumlah *hidden nodes*, yang ditunjukkan dengan slope yang negatif (*red dashed-line*). Model dari trend korelasi tersebut dianggap sudah baik dengan indikasi nilai *correlation coefficient* (r) dan (*coefficient of determination*) r^2 (Cohen, 1988) dan korelasinya *significant* yang ditunjukkan dengan *P-value*. Trend tersebut menggambarkan bahwa arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik.

4.3.1.3. Model NN Terbaik

Dari plot pada Gambar 4.4 dan 4.5 terlihat bahwa model no. 9 menunjukkan kinerja yang terbaik. Dengan melihat kembali Gambar 4.7, dimana model arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik. Sebagai contoh dengan menggunakan jumlah hidden nodes 25 hingga 30, seperti yang ditunjukkan pada Gambar 4.8, model NN mampu menghasilkan akurasi yang tinggi pada semua *stress ratio*, dengan pengecualian pada jumlah hidden nodes 25, 26 dan 29, dimana akurasi pada $R = -2$ menunjukkan lebih rendah dari yang lain tetapi nilainya sudah sangat mendekati akurasi yang tinggi. Tabel 4.6 menunjukkan nilai R^2 rata-rata dengan jumlah *hidden nodes* 25 hingga 30 adalah 0.9370 ± 0.028 , yang menunjukkan bahwa model NN ini mampu menghasilkan akurasi yang tinggi.

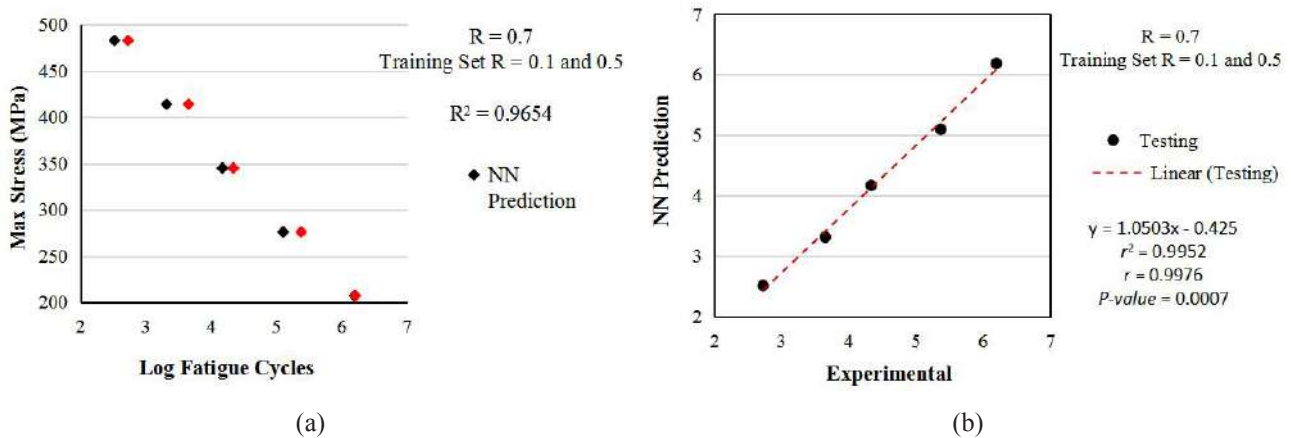



Gambar 4.8. Plot akurasi dalam R^2 dari dari model no. 9 dengan jumlah hidden nodes 25 hingga 30.

4.3.2. Hasil Simulasi Dengan Material 2


4.3.2.1. Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental

Hasil simulasi dengan akurasi testing terbaik ditunjukkan pada Gambar 4.9 yang merupakan hasil prediksi model NN dengan training set 1, iterasi maksimum 100 dan jumlah hidden nodes = 22. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.







(c)




(d)




(e)





(f)

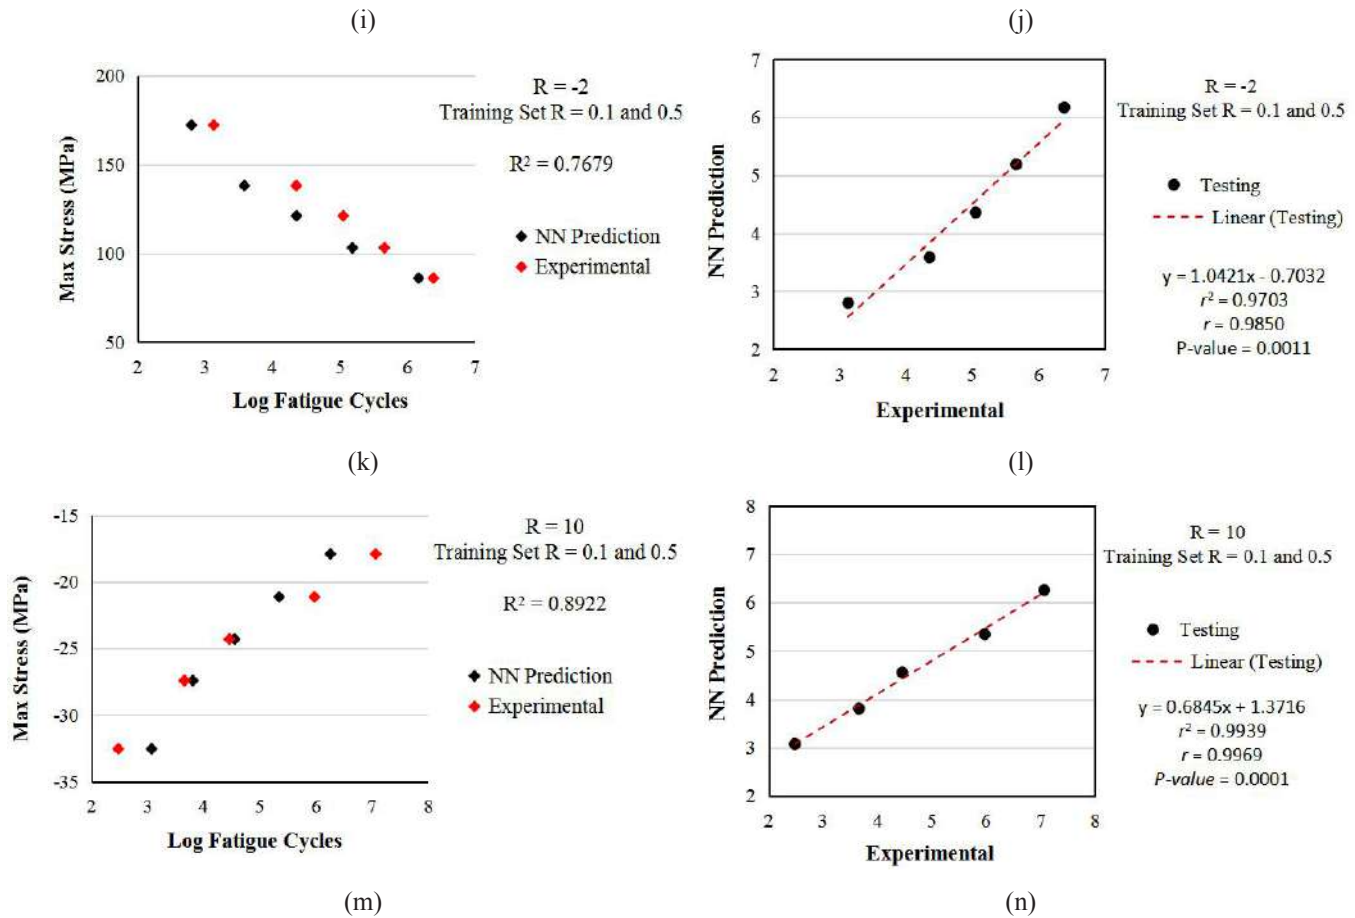


(g)




(h)






Gambar 4.9. *S-N curve* dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 2, dengan training Set 1, iterasi maksimum 100 dan jumlah hidden nodes = 22. (a) *S-N curve* $R = 0.7$. (b) Korelasi pada $R = 0.7$. (c) *S-N curve* $R = 0.8$. (d) Korelasi pada $R = 0.8$. (e) *S-N curve* $R = 0.9$. (f) Korelasi pada $R = 0.9$. (g) *S-N curve* $R = -0.5$. (h) Korelasi pada $R = -0.5$. (i) *S-N curve* $R = -1$. (j) Korelasi pada $R = -1$. (k) *S-N curve* $R = -2$. (l) Korelasi pada $R = -2$. (m) *S-N curve* $R = 10$. (n) Korelasi pada $R = 10$.


Hasil simulasi dengan akurasi testing paling rendah ditunjukkan pada Gambar 4.10 yang merupakan hasil prediksi model NN dengan training set 1, iterasi maksimum 50 dan jumlah hidden nodes = 6. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.




(a)




(b)




(c)





(d)

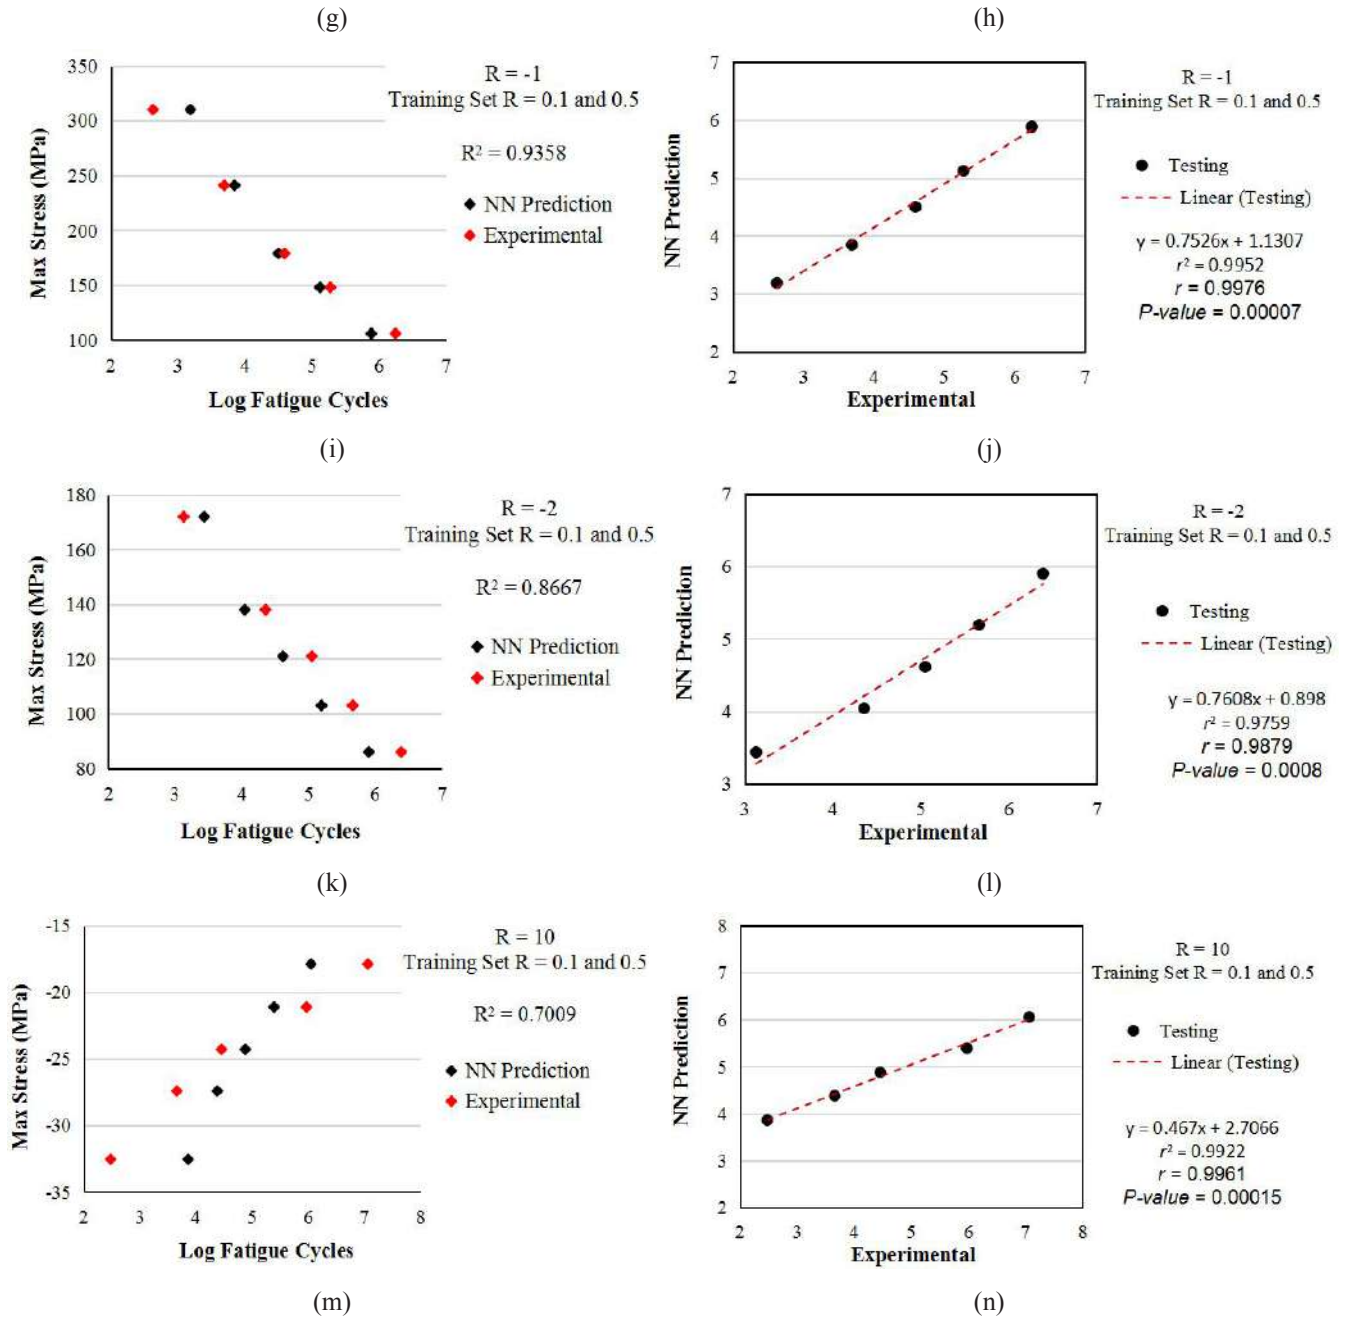


(e)



(f)







Gambar 4.10. *S-N curve* dan korelasi berdasarkan prediksi MLP-GA dan data experimental untuk material 2, dengan training Set 1, iterasi maksimum 50 dan jumlah hidden nodes = 6. (a) *S-N curve* $R = 0.7$. (b) Korelasi pada $R = 0.7$. (c) *S-N curve* $R = 0.8$. (d) Korelasi pada $R = 0.8$. (e) *S-N curve* $R = 0.9$. (f) Korelasi pada $R = 0.9$. (g) *S-N curve* $R = -0.5$. (h) Korelasi pada $R = -0.5$ (i) *S-N curve* $R = -1$. (j) Korelasi pada $R = -1$ (k) *S-N curve* $R = -2$. (l) Korelasi pada $R = -2$ (m) *S-N curve* $R = 10$. (n) Korelasi pada $R = 10$

4.3.2.2. Akurasi Prediksi Model NN

Akurasi prediksi model NN dalam bentuk plot nilai *MSE* (maksimum, rata-rata, dan minimum) dan distribusi normal (dengan $\alpha = 0.05$) disajikan pada Gambar 4.11. Plot nilai *MSE* rata-rata dan *confidence interval* (dengan $\alpha = 0.05$) dari model NN yang rendah disajikan pada Gambar 4.12. Dengan melihat nilai *MSE* rata-rata, distribusi normal dan *confidence interval*, terlihat model NN dengan training set 2 dengan iterasi maksimum 200 menunjukkan akurasi yang paling tinggi. Sementara itu model NN dengan training set 3 dengan iterasi maksimum 200 menunjukkan akurasi yang paling rendah. Untuk melihat nilai *MSE* (maksimum, rata-rata (*average*), dan minimum) dari masing-masing model NN, bisa dilihat pada Tabel 4.7.



Gambar 4.11. Plot nilai *MSE* (*average*, *minimum* dan *maximum*) dan *error bar* yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-GA untuk material 2. Deskripsi dari Model No. dan nilai *MSE* tersebut ditunjukkan pada Tabel 4.7




Gambar 4.12. Plot nilai *MSE* dan *error bar* yang menunjukkan *confidence interval* dengan $\alpha = 0.05$, dari akurasi MLP-GA untuk material 2, dengan training set 1 dan 2.

Tabel 4.7. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.11 Dan 4.12 Dan Nilai *MSE* (*Average*, *Minimum* dan *Maximum*) Pada Masing-masing Model

Model No.	Training Set	Jumlah Hidden Nodes	Iterasi Maksimum	<i>MSE</i> (<i>average</i>)	<i>MSE</i> Min.	<i>MSE</i> Max.
1	Set 1	6-30	50	0.2995	0.2517	0.4303
2	Set 1	6-30	100	0.2797	0.2378	0.3858
3	Set 1	6-30	200	0.2768	0.2389	0.4055
4	Set 2	6-30	50	0.2713	0.2406	0.3870
5	Set 2	6-30	100	0.2632	0.2383	0.3359
6	Set 2	6-30	200	0.2610	0.2442	0.3231
7	Set 3	6-30	50	0.3012	0.2699	0.3455
8	Set 3	6-30	100	0.3065	0.2786	0.3396
9	Set 3	6-30	200	0.3172	0.2852	0.3596


Akurasi model *NN* yang diukur dalam *MSE* dan R^2 untuk masing-masing *stress ratio* dengan training set 2 dan iterasi maksimum 200 dengan jumlah hidden nodes 6 hingga 30 disajikan pada Tabel 4.8. Dalam hal akurasi (nilai R^2) untuk masing-masing *stress ratio*, nilai maksimum, rata-rata dan minimum disajikan dengan plot pada tiap-tiap *stress ratio* (R) pada Gambar 4.13. Nilai maksimum, rata-rata dan minimum tersebut berdasarkan nilai R^2 dari model dengan hidden nodes 6 hingga 30.



Gambar 4.13. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (*average*) dan minimum) untuk tiap-tiap *stress ratio* (R) dari MLP-GA dengan jumlah *hidden nodes* 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 200

Tabel 4.8. Akurasi Prediksi Model MLP-GA Dengan Nilai MSE dan R^2 Untuk Material 2 Dengan Training Set 2, Iterasi Maksimum 200 Dan Jumlah Hidden Nodes 6 Hingga 30 (model no. 6)

Jumlah Hidden Nodes	MSE	Coefficient of Determination R^2						
		$R = 0.5$	$R = 0.7$	$R = 0.8$	$R = 0.9$	$R = -0.5$	$R = -2$	$R = 10$
6	0.3231	0.8110	0.9682	0.9583	0.8781	0.5181	0.8664	0.7625
7	0.2817	0.8958	0.9898	0.9296	0.8601	0.5179	0.8829	0.8310
8	0.2823	0.8783	0.9907	0.9466	0.8758	0.5528	0.8694	0.8026
9	0.2637	0.8865	0.9946	0.9443	0.8855	0.5720	0.8816	0.8204
10	0.2532	0.8716	0.9963	0.9477	0.9151	0.5705	0.8579	0.8446
11	0.2681	0.8913	0.9935	0.9308	0.8856	0.5437	0.8548	0.8444
12	0.2910	0.9108	0.9904	0.9153	0.8571	0.5678	0.8909	0.7696
13	0.2590	0.8821	0.9950	0.9373	0.8988	0.5304	0.8770	0.8588
14	0.2442	0.8564	0.9953	0.9498	0.9301	0.5550	0.8505	0.8796
15	0.2577	0.8701	0.9951	0.9390	0.9188	0.5383	0.8479	0.8622
16	0.2683	0.8677	0.9945	0.9398	0.9201	0.5130	0.8540	0.8485
17	0.2495	0.8825	0.9923	0.9253	0.9027	0.5350	0.8768	0.8849
18	0.2600	0.8793	0.9909	0.9215	0.9054	0.5406	0.8754	0.8567
19	0.2464	0.8650	0.9936	0.9384	0.9299	0.5694	0.8515	0.8654
20	0.2597	0.8749	0.9925	0.9312	0.9130	0.5341	0.8529	0.8638
21	0.2630	0.8954	0.9913	0.9218	0.8844	0.5380	0.8762	0.8556
22	0.2631	0.8645	0.9923	0.9287	0.9229	0.5362	0.8505	0.8545
23	0.2517	0.8784	0.9945	0.9396	0.9083	0.5270	0.8825	0.8719
24	0.2443	0.8989	0.9938	0.9333	0.8909	0.5639	0.9006	0.8628
25	0.2550	0.8605	0.9947	0.9400	0.9234	0.5113	0.8652	0.8809
26	0.2469	0.8721	0.9961	0.9462	0.9094	0.5520	0.8732	0.8711
27	0.2491	0.8460	0.9954	0.9500	0.9423	0.5130	0.8266	0.9029
28	0.2444	0.8613	0.9951	0.9445	0.9302	0.5174	0.8615	0.8987
29	0.2452	0.8831	0.9949	0.9389	0.9050	0.5465	0.8898	0.8727
30	0.2535	0.8857	0.9922	0.9258	0.9028	0.5615	0.8799	0.8531




Gambar 4.14. Plot nilai *MSE* testing terhadap jumlah *hidden nodes* 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 200

Gambar 4.14 adalah menggambarkan plot hubungan antara *MSE* testing terhadap jumlah *hidden nodes* untuk training set 2 dan iterasi maksimum 200. Dari plot tersebut menunjukkan korelasi yang negatif antara *MSE* testing dan jumlah *hidden nodes*, yang ditunjukkan dengan slope yang negatif (*red dashed-line*). Model dari trend korelasi tersebut dianggap sudah baik dengan indikasi nilai *correlation coefficient* (*r*) dan (*coefficient of determination*) r^2 (Cohen, 1988) dan korelasinya significant yang ditunjukkan dengan *P-value*. Trend tersebut menggambarkan bahwa arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik.

4.3.2.3. Model NN Terbaik

Dari plot pada Gambar 4.11 dan 4.12 terlihat bahwa model no. 6 menunjukkan kinerja yang terbaik. Dengan melihat kembali Gambar 4.14, dimana model arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik. Sebagai contoh dengan menggunakan jumlah *hidden nodes* 25 hingga 30, seperti yang ditunjukkan pada Gambar 4.15. Model NN mampu menghasilkan akurasi yang tinggi pada $R = 0.7$, 0.8 dan 0.9. Pada $R = 0.5$, -2 dan 10, model NN belum mampu menghasilkan akurasi yang tinggi akan tetapi nilainya sudah mendekati akurasi yang tinggi. Akurasi yang paling rendah ditunjukkan pada $R = -0.5$, dimana akurasinya masih terpaut jauh dari akurasi yang tinggi. Tabel 4.8 menunjukkan nilai R^2 rata-rata

dengan jumlah *hidden nodes* 25 hingga 30 adalah 0.8575 ± 0.141 , yang menunjukkan bahwa model NN ini mampu menghasilkan akurasi yang cukup baik.




Gambar 4.15. Plot akurasi dalam R^2 dari dari model no. 6 dengan jumlah hidden nodes 25 hingga 30.

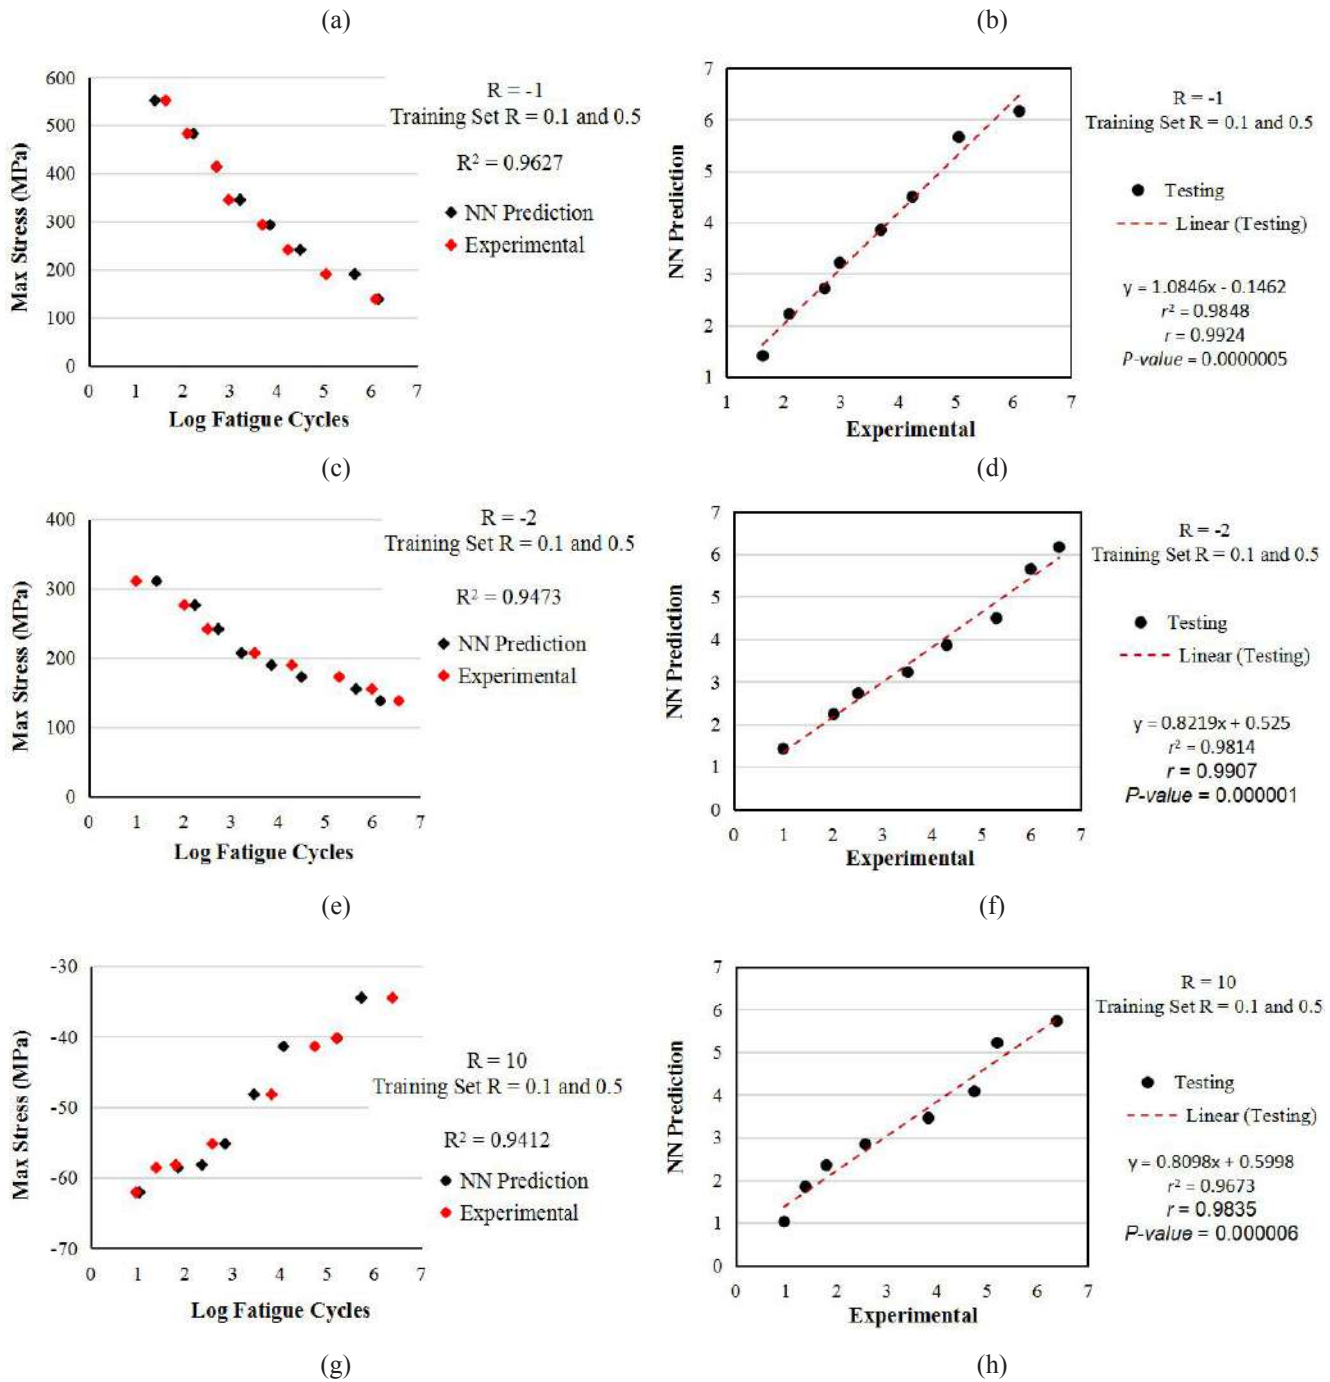
4.4. Simulasi Dengan Hybrid MLP-DE

4.4.1. Hasil Simulasi Dengan Material 1

4.4.1.1. Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental

Hasil simulasi dengan akurasi testing terbaik ditunjukkan pada Gambar 4.16 yang merupakan hasil prediksi model NN dengan training set 1, iterasi maksimum 200 dan jumlah hidden nodes = 20. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.







Gambar 4.16. *S-N curve* dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 1, dengan training Set 1, iterasi maksimum 200 dan jumlah hidden nodes = 20. (a) *S-N curve* $R = -0.5$. (b) Korelasi pada $R = -0.5$. (c) *S-N curve* $R = -1$. (d) Korelasi pada $R = -1$. (e) *S-N curve* $R = -2$. (f) Korelasi pada $R = -2$. (g) *S-N curve* $R = 10$. (h) Korelasi pada $R = 10$

Hasil simulasi dengan akurasi testing paling rendah ditunjukkan pada Gambar 4.17 yang merupakan hasil prediksi model NN dengan training set 2,


iterasi maksimum 200 dan jumlah hidden nodes = 7. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.




(a)




(b)




(c)




(d)




(e)



(f)



(g)




(h)


Gambar 4.17. *S-N curve* dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 1, dengan training Set 2, iterasi maksimum 200 dan jumlah hidden nodes = 7. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = -0.5$. (d) Korelasi pada $R = -0.5$. (e) *S-N curve* $R = -2$. (f) Korelasi pada $R = -2$. (g) *S-N curve* $R = 10$. (h) Korelasi pada $R = 10$

4.4.1.2. Akurasi Prediksi Model NN

Akurasi prediksi model NN dalam bentuk plot nilai *MSE* (maksimum, rata-rata, dan minimum) dan distribusi normal (dengan $\alpha = 0.05$) disajikan pada Gambar 4.18. Plot nilai *MSE* rata-rata dan *confidence interval* (dengan $\alpha = 0.05$) dari model NN yang rendah disajikan pada Gambar 4.19. Dengan melihat nilai *MSE* rata-rata, distribusi normal dan *confidence interval*, terlihat model NN dengan training set 1 dengan iterasi maksimum 200 menunjukkan akurasi yang paling tinggi. Sementara itu model NN dengan training set 3 dengan iterasi maksimum 200 menunjukkan akurasi yang paling rendah. Untuk melihat nilai *MSE* (maksimum, rata-rata (*average*), dan minimum) dari masing-masing model NN, bisa dilihat pada Tabel 4.9.



Gambar 4.18. Plot nilai *MSE* (*average*, *minimum* dan *maximum*) dan *error bar* yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-DE untuk material 1. Deskripsi dari Model No. dan nilai *MSE* tersebut ditunjukkan pada Tabel 4.9




Gambar 4.19. Plot nilai *MSE* dan *error bar* yang menunjukkan *confidence interval* dengan $\alpha = 0.05$, dari akurasi MLP-DE untuk material 1, dengan training set 1.

Tabel 4.9. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.18 dan 4.19 Dan Nilai MSE (*Average*, *Minimum* dan *Maximum*) Pada Masing-masing Model

Model No.	Training Set	Jumlah Hidden Nodes	Iterasi Maksimum	MSE (<i>average</i>)	MSE Min.	MSE Max.
1	Set 1	6-30	50	0.1814	0.1394	0.2455
2	Set 1	6-30	100	0.1700	0.1292	0.2797
3	Set 1	6-30	200	0.1652	0.1314	0.2326
4	Set 2	6-30	50	0.2824	0.2379	0.3619
5	Set 2	6-30	100	0.2565	0.2175	0.3251
6	Set 2	6-30	200	0.2663	0.2080	0.3997
7	Set 3	6-30	50	0.2696	0.2216	0.3356
8	Set 3	6-30	100	0.2754	0.2075	0.3739
9	Set 3	6-30	200	0.2808	0.1959	0.3760


Akurasi model NN yang diukur dalam MSE dan R^2 untuk masing-masing *stress ratio* dengan training set 1 dan iterasi maksimum 200 dengan jumlah hidden nodes 6 hingga 30 disajikan pada Tabel 4.10. Dalam hal akurasi (nilai R^2) untuk masing-masing *stress ratio*, nilai maksimum, rata-rata dan minimum disajikan dengan plot pada tiap-tiap *stress ratio* (R) pada Gambar 4.20.



Gambar 4.20. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (*average*) dan minimum) untuk tiap-tiap *stress ratio* (R) dari MLP-DE dengan jumlah *hidden nodes* 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200

Tabel 4.10. Akurasi Prediksi Model MLP-DE Dengan Nilai *MSE* dan R^2 Untuk Material 1 Dengan Training Set 1, Iterasi Maksimum 200 Dan Jumlah *Hidden Nodes* 6 Hingga 30

Jumlah Hidden Nodes	<i>MSE</i>	Coefficient of Determination R^2			
		<i>R</i> = -0.5	<i>R</i> = -1	<i>R</i> = -2	<i>R</i> = 10
6	0.2326	0.9725	0.9658	0.9313	0.8349
7	0.1967	0.9713	0.9701	0.9334	0.8729
8	0.1762	0.9714	0.9704	0.9371	0.8828
9	0.1745	0.9703	0.9652	0.9409	0.8947
10	0.1859	0.9723	0.9632	0.9406	0.8816
11	0.2314	0.9703	0.9661	0.9411	0.8276
12	0.1947	0.9685	0.9688	0.9378	0.8733
13	0.1411	0.9684	0.9674	0.9402	0.9342
14	0.1529	0.9695	0.9672	0.9422	0.9180
15	0.1702	0.9723	0.9697	0.9358	0.9010
16	0.1435	0.9690	0.9664	0.9414	0.9306
17	0.2036	0.9685	0.9699	0.9364	0.8636
18	0.1394	0.9689	0.9660	0.9440	0.9330
19	0.1532	0.9660	0.9632	0.9443	0.9200
20	0.1314	0.9683	0.9627	0.9473	0.9412
21	0.1370	0.9681	0.9629	0.9468	0.9353
22	0.2069	0.9662	0.9683	0.9354	0.8632
23	0.1452	0.9665	0.9642	0.9455	0.9272
24	0.1843	0.9684	0.9667	0.9412	0.8832
25	0.1526	0.9679	0.9663	0.9422	0.9198
26	0.1374	0.9697	0.9693	0.9403	0.9366
27	0.1389	0.9673	0.9641	0.9460	0.9336
28	0.1325	0.9693	0.9684	0.9410	0.9423
29	0.1321	0.9664	0.9641	0.9449	0.9432
30	0.1347	0.9668	0.9623	0.9480	0.9378




Gambar 4.21. Plot nilai *MSE* testing terhadap jumlah *hidden nodes* 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200

Gambar 4.21 adalah menggambarkan plot hubungan antara *MSE* testing terhadap jumlah *hidden nodes* untuk training set 1 dan iterasi maksimum 200. Dari plot tersebut menunjukkan korelasi yang negatif antara *MSE* testing dan jumlah *hidden nodes*, yang ditunjukkan dengan slope yang negatif (*red dashed-line*). Model dari trend korelasi tersebut dianggap sudah baik dengan indikasi nilai *correlation coefficient* (*r*) dan (*coefficient of determination*) r^2 (Cohen, 1988) dan korelasinya significant yang ditunjukkan dengan *P-value*. Trend tersebut menggambarkan bahwa arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik.

4.4.1.3. Model NN Terbaik

Dari plot pada Gambar 4.18 dan 4.19 terlihat bahwa model no. 3 menunjukkan kinerja yang terbaik. Dengan melihat kembali Gambar 4.21, dimana model arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik. Sebagai contoh dengan menggunakan jumlah *hidden nodes* 25 hingga 30, seperti yang ditunjukkan pada Gambar 4.22, model NN mampu menghasilkan akurasi yang tinggi pada semua *stress ratio*. Tabel 4.10 menunjukkan nilai R^2 rata-rata dengan jumlah *hidden nodes* 25 hingga 30 adalah 0.9532 ± 0.015 , yang menunjukkan bahwa model NN ini mampu menghasilkan akurasi yang tinggi.





Gambar 4.22. Plot akurasi dalam R^2 dari dari model no. 3 dengan jumlah hidden nodes 25 hingga 30.

4.4.2. Hasil Simulasi Dengan Material 2


4.4.2.1. Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental

Hasil simulasi dengan akurasi testing terbaik ditunjukkan pada Gambar 4.23 yang merupakan hasil prediksi model NN dengan training set 2, iterasi maksimum 50 dan jumlah hidden nodes = 21. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.







(c)




(d)




(e)




(f)




(g)




(h)




(i)




(j)




(k)



(l)




(m)




(n)

Gambar 4.23. *S-N curve* dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 2, dengan training Set 2, iterasi maksimum 50 dan jumlah hidden nodes = 21. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = 0.7$. (d) Korelasi pada $R = 0.7$. (e) *S-N curve* $R = 0.8$. (f) Korelasi pada $R = 0.8$. (g) *S-N curve* $R = 0.9$. (h) Korelasi pada $R = 0.9$ (i) *S-N curve* $R = -0.5$. (j) Korelasi pada $R = -0.5$ (k) *S-N curve* $R = -2$. (l) Korelasi pada $R = -2$ (m) *S-N curve* $R = 10$. (n) Korelasi pada $R = 10$


Hasil simulasi dengan akurasi testing paling rendah ditunjukkan pada Gambar 4.24 yang merupakan hasil prediksi model NN dengan training set 3, iterasi maksimum 200 dan jumlah hidden nodes = 23. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.




(a)




(b)




(c)




(d)




(e)




(f)




(g)




(h)




(i)





(j)



(k)



(l)




(m)

(n)


Gambar 4.24. *S-N curve* dan korelasi berdasarkan prediksi MLP-DE dan data experimental untuk material 2, dengan training Set 3, iterasi maksimum 200 dan jumlah hidden nodes = 6. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = 0.7$. (d) Korelasi pada $R = 0.7$. (e) *S-N curve* $R = 0.8$. (f) Korelasi pada $R = 0.8$. (g) *S-N curve* $R = 0.9$. (h) Korelasi pada $R = 0.9$ (i) *S-N curve* $R = -0.5$. (j) Korelasi pada $R = -0.5$ (k) *S-N curve* $R = -1$. (l) Korelasi pada $R = -1$ (m) *S-N curve* $R = -2$. (n) Korelasi pada $R = -2$

4.4.2.2. Akurasi Prediksi Model NN

Akurasi prediksi model NN dalam bentuk plot nilai *MSE* (maksimum, rata-rata, dan minimum) dan distribusi normal (dengan $\alpha = 0.05$) disajikan pada Gambar 4.25. Plot nilai *MSE* rata-rata dan *confidence interval* (dengan $\alpha = 0.05$) dari model NN yang rendah disajikan pada Gambar 4.26. Dengan melihat nilai *MSE* rata-rata, distribusi normal dan *confidence interval*, terlihat model NN dengan training set 2 dengan iterasi maksimum 50 menunjukkan akurasi yang paling tinggi. Sementara itu model NN dengan *training set* 3 dengan iterasi maksimum 200 menunjukkan akurasi yang paling rendah. Untuk melihat nilai *MSE* (maksimum, rata-rata (*average*), dan minimum) dari masing-masing model NN, bisa dilihat pada Tabel 4.11.



Gambar 4.25. Plot nilai *MSE* (*average*, *minimum* dan *maximum*) dan *error bar* yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-DE untuk material 2. Deskripsi dari Model No. dan nilai *MSE* tersebut ditunjukkan pada Tabel 4.11




Gambar 4.26. Plot nilai MSE dan $error\ bar$ yang menunjukkan *confidence interval* dengan $\alpha = 0.05$, dari akurasi MLP-DE untuk material 2, dengan training set 1 dan 2.

Tabel 4.11. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.25 Dan 4.26 Dan Nilai MSE (*Average*, *Minimum* dan *Maximum*) Pada Masing-masing Model

Model No.	Training Set	Jumlah Hidden Nodes	Iterasi Maksimum	MSE (average)	MSE Min.	MSE Max.
1	Set 1	6-30	50	0.2566	0.2432	0.2845
2	Set 1	6-30	100	0.2653	0.2392	0.2890
3	Set 1	6-30	200	0.2606	0.2385	0.2780
4	Set 2	6-30	50	0.2506	0.2385	0.2761
5	Set 2	6-30	100	0.2544	0.2414	0.2946
6	Set 2	6-30	200	0.2511	0.2395	0.2739
7	Set 3	6-30	50	0.4001	0.3562	0.4380
8	Set 3	6-30	100	0.4005	0.3760	0.4350
9	Set 3	6-30	200	0.4014	0.3671	0.4467


Akurasi model NN yang diukur dalam MSE dan R^2 untuk masing-masing *stress ratio* dengan training set 2 dan iterasi maksimum 50 dengan jumlah hidden nodes 6 hingga 30 disajikan pada Tabel 4.12. Dalam hal akurasi (nilai R^2) untuk masing-masing *stress ratio*, nilai maksimum, rata-rata dan minimum disajikan dengan plot pada tiap-tiap *stress ratio* (R) pada Gambar 4.27.



Gambar 4.27. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (*average*) dan minimum) untuk tiap-tiap *stress ratio* (R) dari MLP-DE dengan jumlah *hidden nodes* 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50

Tabel 4.12. Akurasi Prediksi Model MLP-DE Dengan Nilai MSE dan R^2 Untuk Material 2 Dengan Training Set 2, Iterasi Maksimum 50 Dan Jumlah Hidden Nodes 6 Hingga 30


Jumlah Hidden Nodes	MSE	Coefficient of Determination R^2						
		$R = 0.5$	$R = 0.7$	$R = 0.8$	$R = 0.9$	$R = -0.5$	$R = -2$	$R = 10$
6	0.2539	0.8800	0.9850	0.9067	0.9028	0.5443	0.8591	0.8896
7	0.2535	0.8587	0.9864	0.9161	0.9255	0.5229	0.8390	0.9048
8	0.2588	0.8707	0.9861	0.9124	0.9138	0.5439	0.8485	0.8759
9	0.2399	0.8612	0.9875	0.9232	0.9322	0.5374	0.8594	0.9111
10	0.2485	0.8487	0.9908	0.9370	0.9398	0.5182	0.8493	0.8993
11	0.2607	0.8545	0.9872	0.9216	0.9336	0.5342	0.8419	0.8706
12	0.2761	0.8653	0.9837	0.9089	0.9203	0.5307	0.8355	0.8468
13	0.2599	0.8657	0.9839	0.9067	0.9186	0.5406	0.8552	0.8754
14	0.2489	0.8498	0.9875	0.9196	0.9336	0.5177	0.8312	0.9208
15	0.2492	0.8533	0.9863	0.9200	0.9361	0.5303	0.8407	0.9040
16	0.2456	0.8588	0.9887	0.9270	0.9350	0.5304	0.8556	0.8997
17	0.2427	0.8446	0.9893	0.9320	0.9493	0.5292	0.8481	0.9066
18	0.2471	0.8484	0.9867	0.9225	0.9415	0.5125	0.8282	0.9249
19	0.2420	0.8620	0.9889	0.9288	0.9324	0.5358	0.8658	0.8997
20	0.2420	0.8585	0.9882	0.9220	0.9318	0.5257	0.8489	0.9203
21	0.2385	0.8559	0.9878	0.9234	0.9393	0.5381	0.8547	0.9143
22	0.2487	0.8584	0.9884	0.9255	0.9331	0.5237	0.8414	0.9050
23	0.2551	0.8490	0.9888	0.9258	0.9361	0.5053	0.8414	0.9030
24	0.2473	0.8537	0.9888	0.9295	0.9382	0.5236	0.8383	0.9070
25	0.2481	0.8519	0.9859	0.9181	0.9345	0.5220	0.8302	0.9204
26	0.2468	0.8582	0.9886	0.9287	0.9360	0.5328	0.8460	0.8983
27	0.2440	0.8425	0.9862	0.9232	0.9472	0.5262	0.8308	0.9217
28	0.2501	0.8345	0.9900	0.9358	0.9522	0.5114	0.8394	0.9043
29	0.2568	0.8428	0.9836	0.9118	0.9396	0.5123	0.8224	0.9134
30	0.2610	0.8563	0.9865	0.9172	0.9290	0.5258	0.8333	0.8840



Gambar 4.28. Plot nilai *MSE* testing terhadap jumlah *hidden nodes* 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50

Gambar 4.28 adalah menggambarkan plot hubungan antara *MSE* testing terhadap jumlah *hidden nodes* untuk training set 2 dan iterasi maksimum 50. Model dari trend korelasi tersebut dianggap kurang baik dengan indikasi nilai *correlation coefficient* (r) dan (*coefficient of determination*) r^2 yang rendah (Cohen, 1988) dan korelasinya yang tidak significant yang ditunjukkan dengan *P-value*, sehingga seolah-olah tidak ada korelasi antara akurasi dengan jumlah *hidden nodes*.


Jika jumlah *hidden nodes* direduksi menjadi 6 hingga 21, maka korelasi antara akurasi dengan jumlah *hidden nodes* menjadi significant, dengan indikasi nilai *P-value* seperti yang ditunjukkan pada Gambar 4.29. Dari nilai r dan r^2 nya terlihat bahwa korelasi tersebut adalah tinggi (Cohen, 1988). *Trend* dari korelasi tersebut menggambarkan bahwa arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik.



Gambar 4.29. Plot nilai *MSE* testing terhadap jumlah *hidden nodes* 6 hingga 21 untuk material 2, dengan training set 2 dan iterasi maksimum 50

4.4.2.3. Model NN Terbaik

Dari plot pada Gambar 4.25 dan 4.26 terlihat bahwa model no. 4 menunjukkan kinerja yang terbaik. Dengan melihat kembali Gambar 4.28 sulit ditentukan model terbaiknya karena korelasinya yang tidak significant. Namun dengan melihat Gambar 29 bisa dilihat pada jumlah *hidden nodes* berapa model NN menunjukkan akurasi yang bagus. Jika model NN menggunakan jumlah hidden nodes 14 hingga 21, seperti yang ditunjukkan pada Gambar 4.30, model NN mampu menghasilkan akurasi yang tinggi pada $R = 0.7, 0.8, 0.9$ dan 10, dengan pengecualian pada $R = 10$ dengan jumlah *hidden nodes* = 16 yang menunjukkan kinerja $R^2 = 0.8997$ yang sudah sangat dekat dengan akurasi tinggi. Pada $R = 0.5$ dan -2 , model NN belum mampu menghasilkan akurasi yang tinggi akan tetapi nilainya sudah mendekati akurasi yang tinggi. Akurasi yang paling rendah ditunjukkan pada $R = -0.5$, dimana akurasinya masih terpaut jauh dari akurasi yang tinggi. Tabel 4.12 menunjukkan nilai R^2 rata-rata dengan jumlah *hidden nodes* 25 hingga 30 adalah 0.8556 ± 0.143 , yang menunjukkan bahwa model NN ini mampu menghasilkan akurasi yang cukup baik.



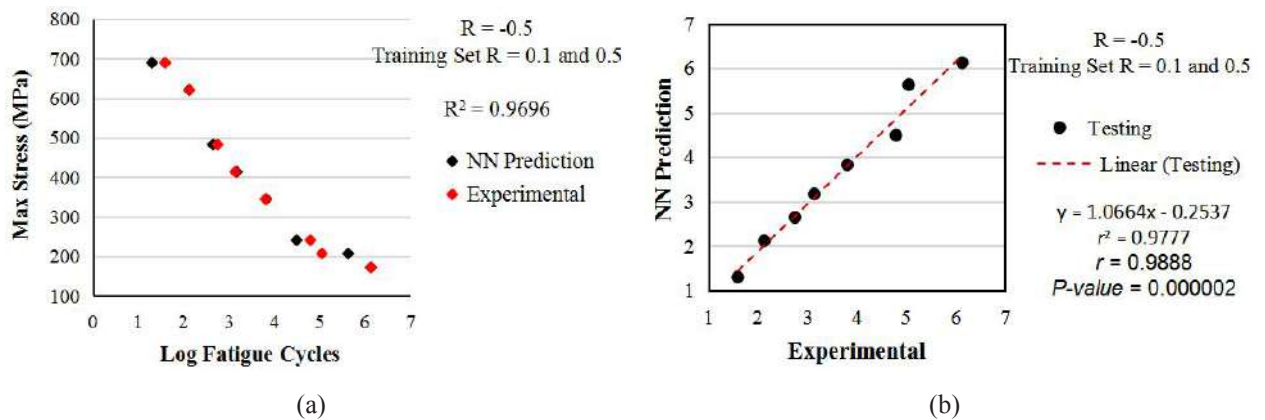
Gambar 4.30. Plot akurasi dalam R^2 dari dari model no. 4 dengan jumlah hidden nodes 14 hingga 21.


4.5. Simulasi Dengan Hybrid MLP-PSO

4.5.1. Hasil Simulasi Dengan Material 1


4.5.1.1. Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental

Hasil simulasi dengan akurasi testing terbaik ditunjukkan pada Gambar 4.31 yang merupakan hasil prediksi model NN dengan training set 1, iterasi maksimum 200 dan jumlah hidden nodes = 23. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.







(c)




(d)




(e)



(f)



(g)




(h)


Gambar 4.31. *S-N curve* dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 1, dengan training Set 1, iterasi maksimum 200 dan jumlah hidden nodes = 23. (a) *S-N curve* $R = -0.5$. (b) Korelasi pada $R = -0.5$. (c) *S-N curve* $R = -1$. (d) Korelasi pada $R = -1$. (e) *S-N curve* $R = -2$. (f) Korelasi pada $R = -2$. (g) *S-N curve* $R = 10$. (h) Korelasi pada $R = 10$

Hasil simulasi dengan akurasi testing paling rendah ditunjukkan pada Gambar 4.32 yang merupakan hasil prediksi model NN dengan training set 2, iterasi maksimum 200 dan jumlah hidden nodes = 9. Dari gambar-gambar


tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.




(a)




(b)




(c)




(d)




(e)



(f)



(g)




(h)


Gambar 4.32. *S-N curve* dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 1, dengan training Set 2, iterasi maksimum 200 dan jumlah hidden nodes = 9. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = -0.5$. (d) Korelasi pada $R = -0.5$. (e) *S-N curve* $R = -2$. (f) Korelasi pada $R = -2$. (g) *S-N curve* $R = 10$. (h) Korelasi pada $R = 10$

4.5.1.2. Akurasi Prediksi Model NN

Akurasi prediksi model NN dalam bentuk plot nilai *MSE* (maksimum, rata-rata, dan minimum) dan distribusi normal (dengan $\alpha = 0.05$) disajikan pada Gambar 4.33. Plot nilai *MSE* rata-rata dan *confidence interval* (dengan $\alpha = 0.05$) dari model NN yang rendah disajikan pada Gambar 4.34. Dengan melihat nilai *MSE* rata-rata, distribusi normal dan *confidence interval*, terlihat model NN dengan training set 1 dengan iterasi maksimum 200 menunjukkan akurasi yang paling tinggi. Sementara itu model NN dengan training set 2 dengan iterasi maksimum 200 menunjukkan akurasi yang paling rendah. Untuk melihat nilai *MSE* (maksimum, rata-rata (*average*), dan minimum) dari masing-masing model NN, bisa dilihat pada Tabel 4.13.



Gambar 4.33. Plot nilai *MSE* (*average*, *minimum* dan *maximum*) dan *error bar* yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-PSO untuk material 1. Deskripsi dari Model No. dan nilai *MSE* tersebut ditunjukkan pada Tabel 4.13




Gambar 4.34. Plot nilai *MSE* dan *confidence interval* dengan $\alpha = 0.05$, dari akurasi MLP-PSO untuk material 1, dengan training set 1.

Tabel 4.13. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.33 Dan 4.34 Dan Nilai *MSE* (*Average*, *Minimum* dan *Maximum*) Pada Masing-masing Model

Model No.	Training Set	Jumlah Hidden Nodes	Iterasi Maksimum	<i>MSE</i> (<i>average</i>)	<i>MSE</i> Min.	<i>MSE</i> Max.
1	Set 1	6-30	50	0.1974	0.1456	0.2820
2	Set 1	6-30	100	0.2051	0.1408	0.2898
3	Set 1	6-30	200	0.1960	0.1369	0.2929
4	Set 2	6-30	50	0.3146	0.2609	0.4030
5	Set 2	6-30	100	0.3162	0.2534	0.4000
6	Set 2	6-30	200	0.3232	0.2469	0.4238
7	Set 3	6-30	50	0.2445	0.1865	0.3489
8	Set 3	6-30	100	0.2403	0.1851	0.3159
9	Set 3	6-30	200	0.2406	0.1912	0.3169


Akurasi model NN yang diukur dalam *MSE* dan R^2 untuk masing-masing *stress ratio* dengan training set 1 dan iterasi maksimum 200 dengan jumlah hidden nodes 6 hingga 30 disajikan pada Tabel 4.14. Dalam hal akurasi (nilai R^2) untuk masing-masing *stress ratio*, nilai maksimum, rata-rata dan minimum disajikan dengan plot pada tiap-tiap *stress ratio* (R) pada Gambar 4.35.



Gambar 4.35. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (*average*) dan minimum) untuk tiap-tiap *stress ratio* (R) dari MLP-PSO dengan jumlah *hidden nodes* 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200

Tabel 4.14. Akurasi Prediksi Model MLP-PSO Dengan Nilai MSE dan R^2 Untuk Material 1 Dengan Training Set 1, Iterasi Maksimum 200 Dan Jumlah *Hidden Nodes* 6 Hingga 30

Jumlah Hidden Nodes	MSE	Coefficient of Determination R^2			
		$R = -0.5$	$R = -1$	$R = -2$	$R = 10$
6	0.2630	0.9749	0.9549	0.9316	0.8040
7	0.2321	0.9732	0.9563	0.9330	0.8389
8	0.2017	0.9725	0.9693	0.9392	0.8468
9	0.2929	0.9708	0.9688	0.9321	0.7630
10	0.2016	0.9667	0.9670	0.9404	0.8647
11	0.2265	0.9658	0.9668	0.9352	0.8415
12	0.1616	0.9662	0.9611	0.9447	0.9109
13	0.2254	0.9677	0.9657	0.9410	0.8365
14	0.2058	0.9688	0.9702	0.9342	0.8629
15	0.1974	0.9712	0.9692	0.9377	0.8683
16	0.2444	0.9721	0.9680	0.9346	0.8167
17	0.1908	0.9709	0.9724	0.9347	0.8773
18	0.2069	0.9698	0.9640	0.9379	0.8609
19	0.1623	0.9705	0.9666	0.9429	0.9060
20	0.1731	0.9669	0.9650	0.9448	0.8946
21	0.1789	0.9701	0.9662	0.9396	0.8904
22	0.1724	0.9711	0.9694	0.9404	0.8947
23	0.1369	0.9696	0.9661	0.9446	0.9348
24	0.1968	0.9685	0.9689	0.9383	0.8702
25	0.1562	0.9713	0.9676	0.9417	0.9133
26	0.1769	0.9651	0.9623	0.9460	0.8917
27	0.1690	0.9675	0.9649	0.9400	0.9039
28	0.1944	0.9694	0.9697	0.9369	0.8735
29	0.1843	0.9654	0.9650	0.9441	0.8831
30	0.1484	0.9642	0.9615	0.9470	0.9250




Gambar 4.36. Plot nilai MSE testing terhadap jumlah *hidden nodes* 6 hingga 30 untuk material 1, dengan training set 1 dan iterasi maksimum 200

Gambar 4.36 adalah menggambarkan plot hubungan antara MSE testing

terhadap jumlah hidden nodes untuk training set 1 dan iterasi maksimum 200. Dari plot tersebut menunjukkan korelasi yang negatif antara *MSE* testing dan jumlah *hidden nodes*, yang ditunjukkan dengan slope yang negatif (*red dashed-line*). Model dari trend korelasi tersebut dianggap sudah baik dengan indikasi nilai *correlation coefficient* (*r*) dan (*coefficient of determination*) r^2 (Cohen, 1988) dan korelasinya significant yang ditunjukkan dengan *P-value*. Trend tersebut menggambarkan bahwa arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik.

4.5.1.3. Model NN Terbaik

Dari plot pada Gambar 4.33 dan 4.34 terlihat bahwa model no. 3 menunjukkan kinerja yang terbaik. Dengan melihat kembali Gambar 4.36, dimana model arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik. Sebagai contoh dengan menggunakan jumlah hidden nodes 25 hingga 30, seperti yang ditunjukkan pada Gambar 4.37, model NN mampu menghasilkan akurasi yang tinggi pada $R = -0.5$, -1 dan -2 . Pada $R = 10$ model NN mampu menghasilkan akurasi yang tinggi pada model NN dengan *hidden nodes* 25, 27 dan 30, sedangkan dengan jumlah *hidden nodes* 26, 28 dan 29 akurasi yang dihasilkan belum mencapai nilai yang tinggi namun nilainya sudah mendekati akurasi tinggi. Tabel 4.14 menunjukkan nilai R^2 rata-rata dengan jumlah *hidden nodes* 25 hingga 30 adalah 0.9433 ± 0.030 , yang menunjukkan bahwa model NN ini mampu menghasilkan akurasi yang tinggi.




Gambar 4.37. Plot akurasi dalam R^2 dari dari model no. 3 dengan jumlah hidden nodes 25 hingga 30.


4.5.2. Hasil Simulasi Dengan Material 2

4.5.2.1. Konsistensi Prediksi Model NN Terhadap Data Kelelahan Experimental


Hasil simulasi dengan akurasi testing terbaik ditunjukkan pada Gambar 4.38 yang merupakan hasil prediksi model NN dengan training set 2, iterasi maksimum 200 dan jumlah hidden nodes = 12. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.




(a)




(b)




(c)




(d)




(e)




(f)




(g)




(h)




(i)



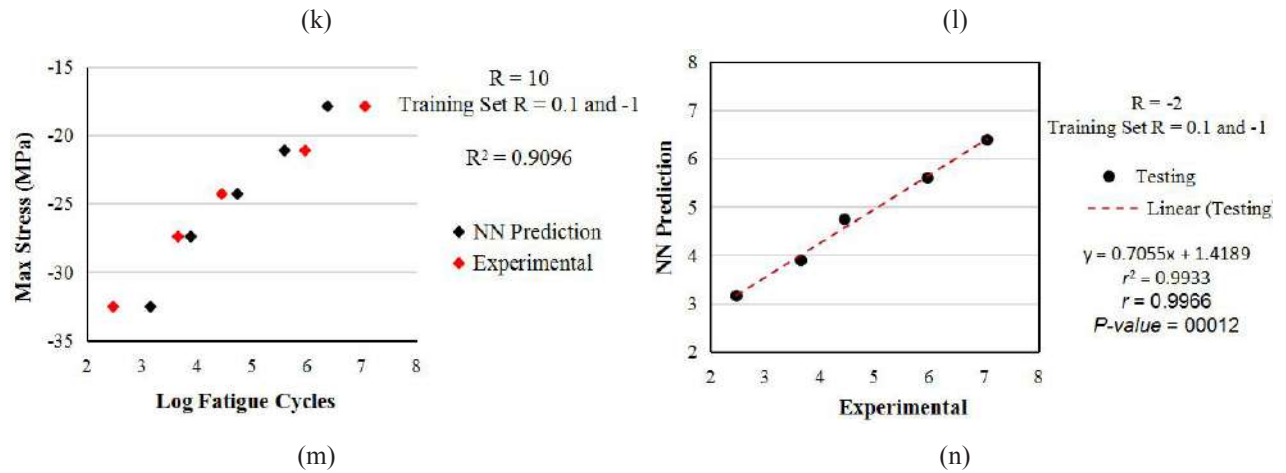
(j)



(i)

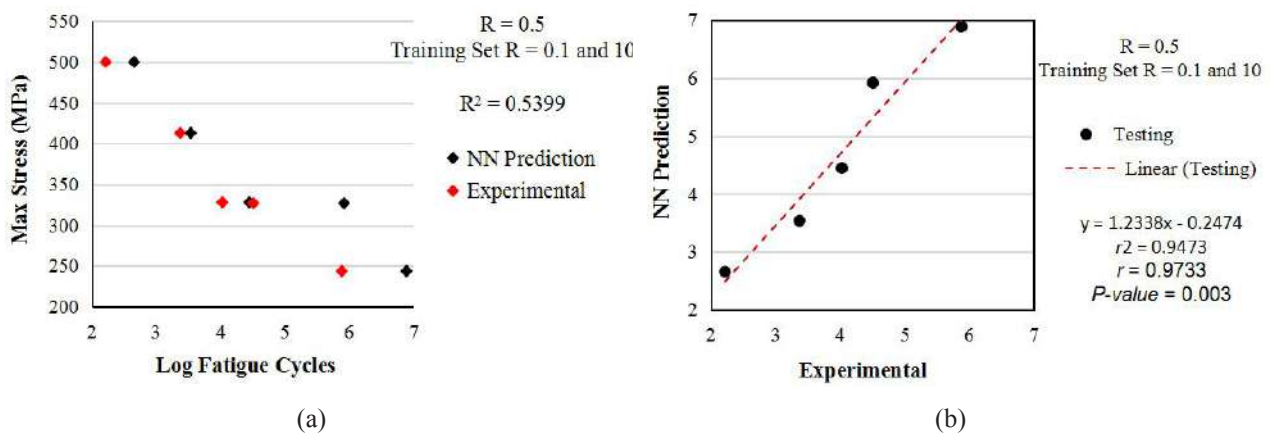



(j)




Gambar 4.38. *S-N curve* dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 2, dengan training Set 2, iterasi maksimum 200 dan jumlah hidden nodes = 12. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = 0.7$. (d) Korelasi pada $R = 0.7$. (e) *S-N curve* $R = 0.8$. (f) Korelasi pada $R = 0.8$. (g) *S-N curve* $R = 0.9$. (h) Korelasi pada $R = 0.9$ (i) *S-N curve* $R = -0.5$. (j) Korelasi pada $R = -0.5$ (k) *S-N curve* $R = -2$. (l) Korelasi pada $R = -2$ (m) *S-N curve* $R = 10$. (n) Korelasi pada $R = 10$

Hasil simulasi dengan akurasi testing paling rendah ditunjukkan pada Gambar 4.39 yang merupakan hasil prediksi model NN dengan training set 3, iterasi maksimum 200 dan jumlah hidden nodes = 26. Dari gambar-gambar tersebut menunjukkan bahwa *trend* prediksi model NN konsisten dengan data kelelahan eksperimental.







(c)




(d)




(e)





(f)

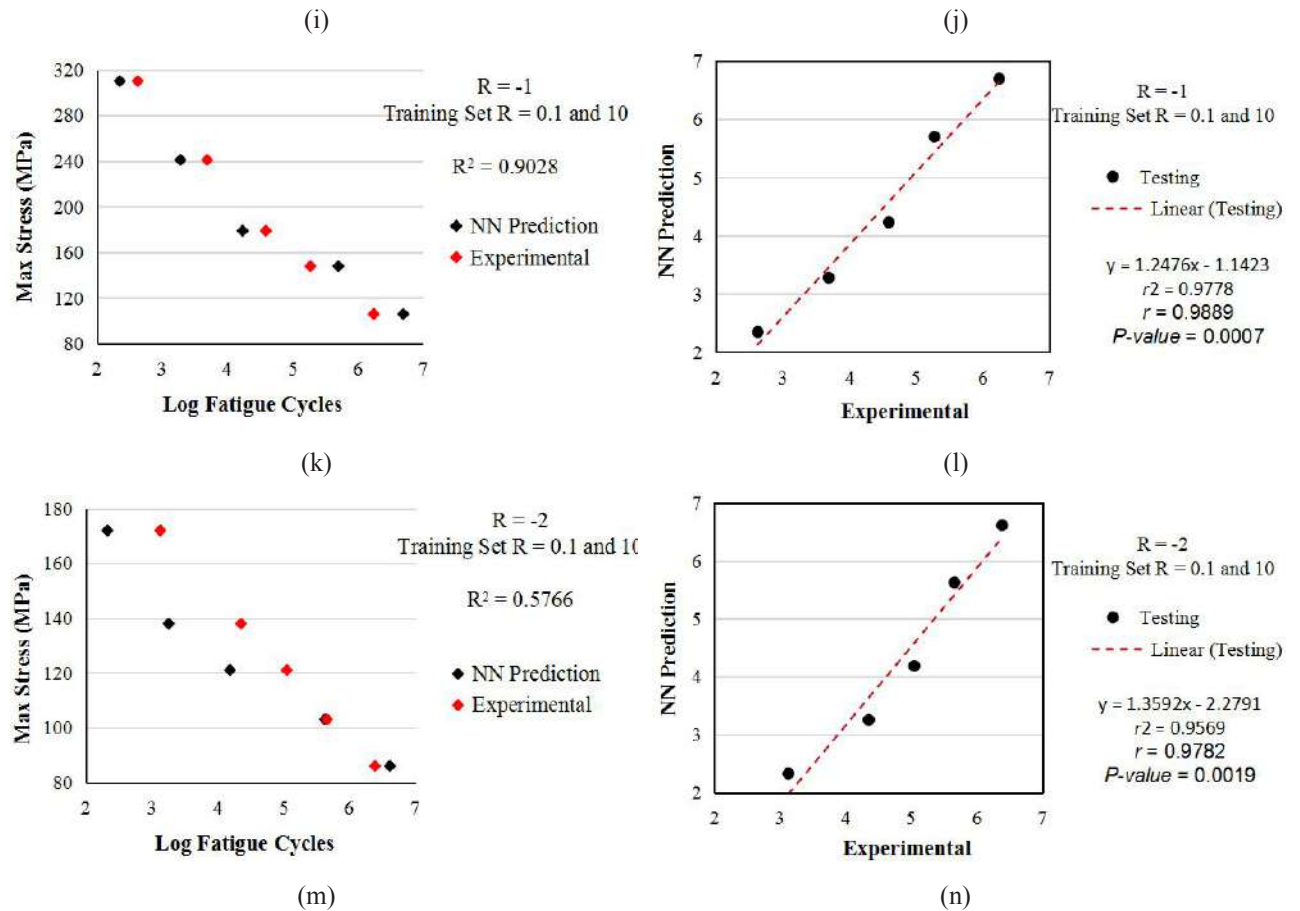


(g)



(h)






Gambar 4.39. *S-N curve* dan korelasi berdasarkan prediksi MLP-PSO dan data experimental untuk material 2, dengan training Set 3, iterasi maksimum 200 dan jumlah hidden nodes = 26. (a) *S-N curve* $R = 0.5$. (b) Korelasi pada $R = 0.5$. (c) *S-N curve* $R = 0.7$. (d) Korelasi pada $R = 0.7$. (e) *S-N curve* $R = 0.8$. (f) Korelasi pada $R = 0.8$. (g) *S-N curve* $R = 0.9$. (h) Korelasi pada $R = 0.9$ (i) *S-N curve* $R = -0.5$. (j) Korelasi pada $R = -0.5$ (k) *S-N curve* $R = -1$. (l) Korelasi pada $R = -1$ (m) *S-N curve* $R = -2$. (n) Korelasi pada $R = -2$


4.5.2.2. Akurasi Prediksi Model NN

Akurasi prediksi model NN dalam bentuk plot nilai *MSE* (maksimum, rata-rata, dan minimum) dan distribusi normal (dengan $\alpha = 0.05$) disajikan pada Gambar 4.40. Plot nilai *MSE* rata-rata dan *confidence interval* (dengan $\alpha = 0.05$) dari model NN yang rendah disajikan pada Gambar 4.41. Dengan melihat nilai *MSE* rata-rata, distribusi normal dan *confidence interval*, terlihat model NN dengan training set 2 dengan iterasi maksimum 50 menunjukkan akurasi yang paling tinggi. Sementara itu model NN dengan training set 3 dengan iterasi

maksimum 200 menunjukkan akurasi yang paling rendah. Untuk melihat nilai *MSE* (maksimum, rata-rata (*average*), dan minimum) dari masing-masing model NN, bisa dilihat pada Tabel 4.15.



Gambar 4.40. Plot nilai *MSE* (*average*, *minimum* dan *maximum*) dan *error bar* yang menunjukkan distribusi normal dengan $\alpha = 0.05$ dari akurasi MLP-PSO untuk material 2. Deskripsi dari Model No. dan nilai *MSE* tersebut ditunjukkan pada Tabel 4.15




Gambar 4.41. Plot nilai *MSE* dan dan *error bar* yang menunjukkan *confidence interval* dengan $\alpha = 0.05$, dari akurasi MLP-PSO untuk material 2, dengan training set 1 dan 2.

Tabel 4.15. Deskripsi Dari “Model No.” Yang Ditunjukkan Pada Gambar 4.40 dan 4.41 Dan Nilai *MSE* (*Average*, *Minimum* dan *Maximum*) Pada Masing-masing Model

Model No.	Training Set	Jumlah Hidden Nodes	Iterasi Maksimum	<i>MSE</i> (<i>average</i>)	<i>MSE</i> Min.	<i>MSE</i> Max.
1	Set 1	6-30	50	0.2587	0.2409	0.2835
2	Set 1	6-30	100	0.2576	0.2336	0.2792
3	Set 1	6-30	200	0.2567	0.2331	0.2843
4	Set 2	6-30	50	0.2489	0.2393	0.2605
5	Set 2	6-30	100	0.2498	0.2346	0.2900
6	Set 2	6-30	200	0.2492	0.2315	0.2650
7	Set 3	6-30	50	0.3845	0.3230	0.4180
8	Set 3	6-30	100	0.3910	0.3458	0.4187
9	Set 3	6-30	200	0.3912	0.3547	0.4353


Akurasi model NN yang diukur dalam *MSE* dan R^2 untuk masing-masing *stress ratio* dengan training set 2 dan iterasi maksimum 50 dengan jumlah hidden nodes 6 hingga 30 disajikan pada Tabel 4.16. Dalam hal akurasi (nilai R^2) untuk masing-masing *stress ratio*, nilai maksimum, rata-rata dan minimum disajikan dengan plot pada tiap-tiap *stress ratio* (R) pada Gambar 4.42.



Gambar 4.42. Nilai akurasi prediksi dalam R^2 (maximum, rata-rata (*average*) dan minimum) untuk tiap-tiap *stress ratio* (R) dari MLP-PSO dengan jumlah *hidden nodes* 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50

Tabel 4.16. Akurasi Prediksi Model MLP-PSO Dengan Nilai *MSE* dan R^2 Untuk Material 2 Dengan Training Set 2, Iterasi Maksimum 50 Dan Jumlah Hidden Nodes 6 Hingga 30

Jumlah Hidden Nodes	<i>MSE</i>	Coefficient of Determination R^2						
		$R = 0.5$	$R = 0.7$	$R = 0.8$	$R = 0.9$	$R = -0.5$	$R = -2$	$R = 10$
6	0.2537	0.8911	0.9836	0.8961	0.8839	0.5476	0.8845	0.8890
7	0.2581	0.8941	0.9880	0.9144	0.8878	0.5482	0.8824	0.8625
8	0.2432	0.8773	0.9876	0.9177	0.9140	0.5498	0.8765	0.8927
9	0.2578	0.8718	0.9897	0.9316	0.9248	0.5580	0.8727	0.8383
10	0.2589	0.8511	0.9839	0.9083	0.9266	0.5062	0.8358	0.9118
11	0.2600	0.8788	0.9876	0.9134	0.9044	0.5484	0.8572	0.8665
12	0.2505	0.8597	0.9889	0.9262	0.9313	0.5282	0.8513	0.8926
13	0.2468	0.8460	0.9856	0.9203	0.9406	0.5329	0.8525	0.9041
14	0.2393	0.8760	0.9891	0.9211	0.9140	0.5560	0.8680	0.9011
15	0.2457	0.8643	0.9889	0.9256	0.9294	0.5275	0.8591	0.9010
16	0.2416	0.8550	0.9904	0.9361	0.9372	0.5500	0.8683	0.8862
17	0.2441	0.8515	0.9890	0.9301	0.9428	0.5339	0.8467	0.9021
18	0.2605	0.8652	0.9883	0.9214	0.9221	0.5324	0.8450	0.8723
19	0.2435	0.8676	0.9884	0.9230	0.9218	0.5481	0.8652	0.8954
20	0.2512	0.8516	0.9887	0.9272	0.9359	0.5138	0.8403	0.9064
21	0.2541	0.8555	0.9853	0.9131	0.9267	0.5242	0.8366	0.9064
22	0.2464	0.8546	0.9879	0.9258	0.9371	0.5291	0.8471	0.9042
23	0.2434	0.8602	0.9893	0.9292	0.9320	0.5408	0.8516	0.9002
24	0.2486	0.8673	0.9870	0.9222	0.9245	0.5584	0.8614	0.8764
25	0.2452	0.8564	0.9891	0.9282	0.9337	0.5281	0.8516	0.9056
26	0.2500	0.8560	0.9894	0.9323	0.9364	0.5381	0.8695	0.8739
27	0.2453	0.8807	0.9889	0.9239	0.9175	0.5658	0.8861	0.8642
28	0.2425	0.8734	0.9875	0.9200	0.9182	0.5454	0.8590	0.9038
29	0.2455	0.8462	0.9877	0.9258	0.9397	0.5186	0.8371	0.9211
30	0.2471	0.8478	0.9852	0.9133	0.9349	0.5379	0.8475	0.9088




Gambar 4.43. Plot nilai *MSE* testing terhadap jumlah *hidden nodes* 6 hingga 30 untuk material 2, dengan training set 2 dan iterasi maksimum 50

Gambar 4.43 adalah menggambarkan plot hubungan antara *MSE* testing terhadap jumlah hidden nodes untuk training set 2 dan iterasi maksimum 50. Model dari trend korelasi tersebut dianggap cukup baik dengan indikasi nilai *correlation coefficient* (r) yang sedang (lebih besar atau sama dengan 0.3) dan korelasinya yang significant yang ditunjukkan dengan *P-value*. *Trend* dari korelasi tersebut menggambarkan bahwa arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik.

4.5.2.3. Model NN Terbaik


Dari plot pada Gambar 4.40 dan 4.41 terlihat bahwa model no. 4 menunjukkan kinerja yang terbaik. Dengan melihat kembali Gambar 4.43, dimana model arsitektur NN dengan semakin banyak jumlah *hidden nodes* cenderung menghasilkan akurasi testing yang lebih baik. Sebagai contoh dengan menggunakan jumlah hidden nodes 25 hingga 30, seperti yang ditunjukkan pada Gambar 4.44, model NN mampu menghasilkan akurasi yang tinggi pada $R = 0.7$, 0.8 dan 0.9. Pada $R = 10$ model NN mampu menghasilkan akurasi yang tinggi kecuali model NN dengan *hidden nodes* 26 dan 27 belum mampu menghasilkan akurasi yang tinggi akan tetapi nilainya sudah mendekati akurasi yang tinggi. Pada $R = 0.5$ dan -2, model NN belum mampu menghasilkan akurasi yang tinggi akan tetapi nilainya sudah mendekati akurasi yang tinggi. Akurasi yang paling rendah ditunjukkan pada $R = -0.5$, dimana akurasinya masih terpaut jauh dari akurasi yang tinggi. Tabel 4.16 menunjukkan nilai R^2 rata-rata dengan jumlah *hidden nodes* 25 hingga 30 adalah 0.8565 ± 0.138 , yang menunjukkan bahwa model NN ini mampu menghasilkan akurasi yang cukup baik.



Gambar 4.44. Plot akurasi dalam R^2 dari dari model no. 4 dengan jumlah hidden nodes 25 hingga 30.

4.6. Akurasi Model NN Berdasarkan Banyaknya Hasil Prediksi Yang Bisa Digunakan

Contoh kurva P - S - N dari data kelelahan hasil eksperimental yang mengandung *scatter* beserta plot umur kelelahan prediksi NN disajikan pada Gambar 4.45. Kurva tersebut adalah mengacu pada material 1 dengan *stress ratio* $R = -2$, dengan plot umur kelelahan prediksi NN dari model *hybrid* MLP-GA. Dari gambar tersebut menunjukkan adanya umur kelelahan prediksi NN yang ditolak karena berada di luar distribusi normal data eksperimental. Mengacu pada distribusi normal data eksperimental, data yang ditolak tersebut memiliki probabilitas $P < 0.025$ atau $P > 0.975$. Gambar kurva P - S - N yang lain ditampilkan pada Lampiran 2.



Gambar 4.45. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -2$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

Akurasi umur kelelahan prediksi NN untuk material 1 dan material 2 yang diukur dengan persamaan 3.5 ditunjukkan pada Tabel 4.17 hingga 4.22, dan dalam bentuk grafik plot akurasi rata-rata terhadap jumlah hidden nodes disajikan pada Gambar 4.46.

Tabel 4.17. Akurasi Prediksi Model MLP-GA Untuk Material 1.

Jumlah <i>hidden</i> <i>nodes</i>	Akurasi (%)				
	$R = 0.5$	$R = -0.5$	$R = -1$	$R = -2$	Rata-rata
25	100	100	100	87.50	96.88
26	87.5	75	100	87.50	87.50
27	100	100	100	75	93.75
28	87.5	75	100	87.50	87.50
29	87.5	75	100	87.50	87.50
30	87.5	75	100	87.50	87.50

Tabel 4.18. Akurasi Prediksi Model MLP-DE Untuk Material 1.

Jumlah <i>hidden</i> <i>nodes</i>	Akurasi (%)				
	$R = -0.5$	$R = -1$	$R = -2$	$R = 10$	Rata-rata
25	100	100	100	62.50	90.63
26	100	100	100	75.00	93.75
27	100	100	100	75.00	93.75
28	100	100	100	87.50	96.88
29	100	100	100	75.00	93.75
30	100	100	100	75.00	93.75

Tabel 4.19. Akurasi Prediksi Model MLP-PSO Untuk Material 1.

Jumlah <i>hidden</i> <i>nodes</i>	Akurasi (%)				
	$R = -0.5$	$R = -1$	$R = -2$	$R = 10$	Rata-rata
25	100	100	100	62.5	90.63
26	100	100	100	62.5	90.63
27	100	100	100	62.5	90.63
28	100	100	100	62.5	90.63
29	100	100	100	75	93.75
30	100	100	100	75	93.75

Tabel 4.20. Akurasi Prediksi Model MLP-GA Untuk Material 2.


Jumlah <i>hidden</i> <i>nodes</i>	Akurasi (%)							
	$R = 0.5$	$R = 0.7$	$R = 0.8$	$R = 0.9$	$R = -0.5$	$R = 10$	$R = -2$	Rata-rata
25	80	100	100	100	0	80	60	74.29
26	80	100	100	100	0	80	60	74.29
27	80	100	100	100	0	80	60	74.29
28	80	100	100	100	0	100	60	77.14
29	80	100	100	100	0	80	60	74.29
30	80	100	100	100	0	80	60	74.29

Tabel 4.21. Akurasi Prediksi Model MLP-DE Untuk Material 2.


Jumlah <i>hidden nodes</i>	Akurasi (%)							Rata- rata
	<i>R</i> = 0.5	<i>R</i> = 0.7	<i>R</i> = 0.8	<i>R</i> = 0.9	<i>R</i> = -0.5	<i>R</i> = 10	<i>R</i> = -2	
14	60	100	100	100	0	100	60	74.29
15	60	100	100	100	0	100	60	74.29
16	60	100	100	100	0	100	60	74.29
17	60	100	100	100	0	100	60	74.29
18	60	100	100	100	0	100	60	74.29
19	60	100	100	100	0	100	60	74.29
20	60	100	100	100	0	100	60	74.29
21	60	100	100	100	0	100	60	74.29

Tabel 4.22. Akurasi Prediksi Model MLP-PSO Untuk Material 2.


Jumlah <i>hidden nodes</i>	Akurasi (%)							Rata- rata
	<i>R</i> = 0.5	<i>R</i> = 0.7	<i>R</i> = 0.8	<i>R</i> = 0.9	<i>R</i> = -0.5	<i>R</i> = 10	<i>R</i> = -2	
25	60	100	100	100	0	80	60	71.43
26	60	100	100	100	0	100	60	74.29
27	80	100	100	100	0	80	60	74.29
28	60	100	100	100	0	80	60	71.43
29	60	100	100	100	0	80	60	71.43
30	60	100	100	100	0	100	60	74.29




(a)




(b)




(c)



(d)



(e)



(f)

Gambar 4.46. Plot akurasi rata-rata dari model NN terhadap jumlah *hidden nodes*. (a) Model MLP-GA, material 1, (b) Model MLP-DE, material 1. (c) Model MLP-PSO, material 1. (d) Model MLP-GA, material 2. (e) Model MLP-DE, material 2. (f) Model MLP-PSO, material 2.

Dari Gambar 4.46 terlihat, dari hasil simulasi dengan material 1 model

MLP-DE menunjukkan akurasi yang paling tinggi, yaitu di atas 90%. Akurasi hasil simulasi dengan material 2 menunjukkan akurasi yang hampir sama, yaitu antara 70% hingga 80%, dan akurasi hasil prediksi dari model MLP-DE menunjukkan nilai yang konstan pada semua hidden nodes (25 hingga 30).

4.7. Analisa Sensitifitas *Hybrid* MLP-GA

Dengan analisa sensitifitas maka akan diketahui tingkat pengaruh parameter dalam pemodelan NN, yaitu training set, iterasi maksimum dan jumlah *hidden nodes* (*net size*). Selain itu interaksi antara parameter tersebut juga bisa diketahui. Metode pengujian yang digunakan adalah ANOVA 3-Faktor. Proses perhitungan menggunakan *software* Minitab.

Ada 3 asumsi dasar dari pengujian ini yaitu pertama, tiap pengujian adalah independen, yang kedua adalah semua data pada tiap eksperimen berdistribusi normal, dan yang ketiga adalah *variance equality*. Dalam studi ini tiap eksperimen telah dilakukan secara independen. Asumsi kedua dan ketiga telah terpenuhi dengan melakukan 30 kali percobaan (Bhattacharya, G.K, dkk, 1977).

Uji hipotesa yang digunakan disajikan pada Tabel 4.23. Respon dalam pengujian ini adalah nilai *MSE* pada tiap percobaan. Dasar perhitungan analisa ANOVA disajikan di Lampiran 3. Metode tersebut digunakan untuk analisa sensitifitas untuk material 1 dan 2 pada model NN hybrid MLP-GA, MLP-DE dan MLP-PSO. Nilai α yang digunakan adalah 0.05 atau tingkat kepercayaan 95%.

Tabel 4.23. Uji Hipotesa Untuk Analisa Sensitifitas

Faktor	Hipotesa	Tes Statistik
Training set	H_0 : <i>Training set</i> tidak berpengaruh secara signifikan terhadap nilai <i>MSE</i> H_1 : <i>Training set</i> berpengaruh secara signifikan terhadap nilai <i>MSE</i>	H_0 Diterima jika $P\text{-value} > \alpha$
Iterasi maksimum	H_0 : Nilai iterasi maksimum tidak berpengaruh secara signifikan terhadap nilai <i>MSE</i> H_1 : Nilai iterasi maksimum berpengaruh secara signifikan terhadap nilai <i>MSE</i>	H_0 Diterima jika $P\text{-value} > \alpha$

<i>Net size</i> (jumlah <i>hidden nodes</i>)	H_0 : <i>Net size</i> tidak berpengaruh secara signifikan terhadap nilai <i>MSE</i> H_1 : <i>Net size</i> berpengaruh secara signifikan terhadap nilai <i>MSE</i>	H_0 Diterima jika $P\text{-value} > \alpha$
Iterasi maksimum * Training set	H_0 : Tidak ada interaksi antara faktor iterasi maksimum dan <i>training set</i> H_1 : Ada interaksi antara faktor iterasi maksimum dan <i>training set</i>	H_0 Diterima jika $P\text{-value} > \alpha$
Iterasi maksimum * <i>Net size</i>	H_0 : Tidak ada interaksi antara faktor iterasi maksimum dan <i>net size</i> H_1 : Ada interaksi antara faktor iterasi maksimum dan <i>net size</i>	H_0 Diterima jika $P\text{-value} > \alpha$
Training set * <i>Net size</i>	H_0 : Tidak ada interaksi antara faktor <i>training set</i> dan <i>net size</i> H_1 : Ada interaksi antara faktor <i>training set</i> dan <i>net size</i>	H_0 Diterima jika $P\text{-value} > \alpha$
Iterasi maksimum * Training set * <i>Net size</i>	H_0 : Tidak ada interaksi antara faktor iterasi maksimum dan <i>training set</i> dan <i>net size</i> H_1 : Ada interaksi antara faktor iterasi maksimum dan <i>training set</i> dan <i>net size</i>	H_0 Diterima jika $P\text{-value} > \alpha$

4.7.1. Analisa Sensitifitas Hasil Simulasi Material 1

Tabel hasil uji ANOVA disajikan pada Gambar 4.47.

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Max_iteration	2	2.030	1.0149	29.12	0.000
Train_set	2	35.816	17.9082	513.89	0.000
Net_size	24	9.988	0.4162	11.94	0.000
Max_iteration*Train_set	4	0.102	0.0256	0.74	0.568
Max_iteration*Net_size	48	1.990	0.0415	1.19	0.174
Train_set*Net_size	48	2.260	0.0471	1.35	0.054
Max_iteration*Train_set*Net_size	96	4.415	0.0460	1.32	0.021
Error	6525	227.385	0.0348		
Total	6749	283.986			

Gambar 4.47. Tabel ANOVA hasil pengujian untuk material 1 dengan *MSE* pada tiap percobaan sebagai respon (MLP-GA).


Dengan melihat nilai *P-value* pada tabel ANOVA hasil pengujian, terlihat bahwa:

- Faktor iterasi maksimum berpengaruh secara signifikan terhadap nilai *MSE*.
- Faktor *training set* berpengaruh secara signifikan terhadap nilai *MSE*
- Faktor *net size* (jumlah *hidden nodes*) berpengaruh secara signifikan terhadap

nilai *MSE*

- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *training set*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *net size* (jumlah *hidden nodes*)
- Pengaruh faktor *training set* terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *net size* (jumlah *hidden nodes*)
- Ada interaksi antara faktor iterasi maksimum dan *training set* dan *net size*

Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.48.




Gambar 4.48. Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* dari pengujian ANOVA untuk material 1 (MLP-GA)

Dari Gambar 4.48 pengaruh faktor *net size* atau jumlah *hidden nodes* menunjukkan semakin banyak jumlah *hidden nodes* akan menghasilkan *MSE* rata-rata yang semakin baik.


Untuk melihat lebih detail pengaruh faktor iterasi maksimum terhadap nilai *MSE* bisa dilihat pada Gambar 4.49, yang menunjukkan perbandingan antara

pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai MSE . Dari plot tersebut terlihat bahwa pengaruh iterasi maksimum terhadap nilai MSE menunjukkan perbedaan yang signifikan, dan terlihat bahwa iterasi maksimum 200 menunjukkan akurasi yang paling tinggi sedangkan iterasi maksimum 50 menunjukkan akurasi yang paling rendah.



Gambar 4.49. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai MSE untuk material 1 (MLP-GA)

Untuk melihat lebih detail pengaruh faktor *training set* terhadap nilai MSE bisa dilihat pada Gambar 4.50, yang menunjukkan perbandingan antara pengaruh *training set* 1, 2 dan 3 terhadap nilai MSE . Dari plot tersebut terlihat bahwa pengaruh *training set* terhadap nilai MSE menunjukkan perbedaan yang signifikan, dan terlihat bahwa *training set* 3 menunjukkan akurasi yang paling tinggi sedangkan *training set* 2 menunjukkan akurasi yang paling rendah.



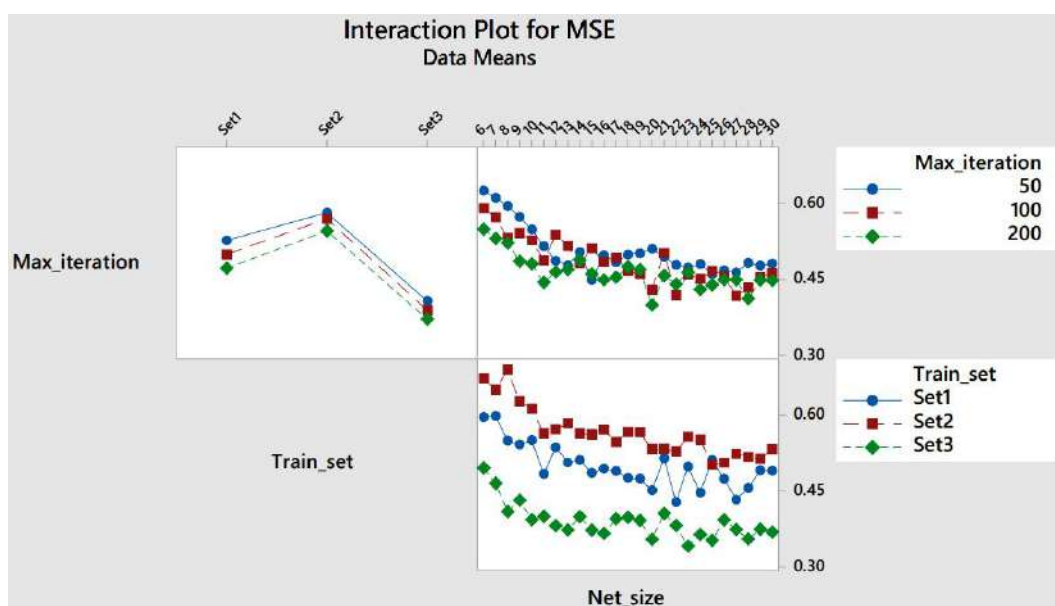
Gambar 4.50. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai *MSE* untuk material 1 (MLP-GA)

Plot interaksi dari pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.51. Dari plot interaksi antara faktor iterasi maksimum dengan faktor *training set* terlihat pengaruh faktor *training set* konsisten untuk iterasi maksimum 50, 100 dan 200, selain itu pengaruh interaksi faktor iterasi maksimum dan *training set* menunjukkan konsisten dengan pengaruh faktor *training set* tanpa interaksi maupun faktor iterasi maksimum tanpa iterasi. Sehingga pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *training set*, begitu juga sebaliknya, pengaruh training set terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Dari plot interaksi tersebut terlihat interaksi antara faktor iterasi maksimum 200 dan *training set* 3 menunjukkan *MSE* rata-rata yang paling rendah.

Dari plot interaksi antara iterasi maksimum dengan *net size* (banyaknya *hidden nodes*) terlihat pengaruh *net size* terhadap iterasi maksimum 50, 100 dan 200 menunjukkan *tend* yang konsisten dengan faktor *net size* tanpa interaksi. Meskipun pada beberapa jumlah *hidden nodes* menunjukkan interaksi yang tidak

konsisten dengan faktor iterasi maksimum namun karena jumlahnya yang sedikit sehingga P -value menunjukkan nilai diatas 0.05. Dengan demikian pengaruh faktor iterasi maksimum terhadap nilai MSE tidak dipengaruhi secara signifikan oleh faktor $net\ size$, begitu juga sebaliknya, pengaruh $net\ size$ terhadap nilai MSE rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Dari plot interaksi tersebut terlihat interaksi antara faktor iterasi maksimum 200 dan jumlah $hidden\ nodes$ yang besar menunjukkan MSE rata-rata yang paling rendah.

Dari plot interaksi antara faktor $training\ set$ dengan faktor $net\ size$ terlihat pengaruh faktor $net\ size$ konsisten semua $training\ set$, selain itu pengaruh interaksi faktor $training\ set$ dan $net\ size$ menunjukkan konsisten dengan pengaruh faktor $net\ size$ tanpa interaksi maupun faktor $training\ set$ tanpa iterasi. Sehingga pengaruh faktor $training\ set$ terhadap nilai MSE tidak dipengaruhi secara signifikan oleh $net\ size$, begitu juga sebaliknya, pengaruh faktor $net\ size$ terhadap nilai MSE rata-rata tidak dipengaruhi secara signifikan oleh faktor $training\ set$. Dari plot interaksi tersebut terlihat interaksi antara $training\ set\ 3$ dan jumlah $hidden\ nodes$ yang besar menunjukkan MSE rata-rata yang paling rendah.



Gambar 4.51. Plot interaksi pengaruh faktor iterasi maksimum, $training\ set$ dan $net\ size$ (jumlah $hidden\ nodes$) terhadap nilai MSE untuk material 1 (MLP-GA)

4.7.2. Analisa Sensitifitas Hasil Simulasi Material 2

Tabel hasil uji ANOVA disajikan pada Gambar 4.52.

Analysis of Variance


Source	DF	Adj SS	Adj MS	F-Value	P-Value
Max_iteration	2	1.371	0.68533	27.83	0.000
Train_set	2	2.101	1.05053	42.66	0.000
Net_size	24	2.330	0.09707	3.94	0.000
Max_iteration*Train_set	4	0.624	0.15606	6.34	0.000
Max_iteration*Net_size	48	1.030	0.02146	0.87	0.722
Train_set*Net_size	48	2.710	0.05646	2.29	0.000
Max_iteration*Train_set*Net_size	96	2.204	0.02296	0.93	0.666
Error	6525	160.671	0.02462		
Total	6749	173.041			

Gambar 4.52. Tabel ANOVA hasil pengujian untuk material 2 dengan *MSE* pada tiap percobaan sebagai respon (MLP-GA).

Dengan melihat nilai *P-value* pada tabel ANOVA hasil pengujian, terlihat bahwa:

- Faktor terasi maksimum berpengaruh secara signifikan terhadap nilai *MSE*.
- Faktor *training set* berpengaruh secara signifikan terhadap nilai *MSE*
- Faktor *net size* (jumlah *hidden nodes*) perpengaruh secara signifikan terhadap nilai *MSE*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* dipengaruhi secara signifikan oleh *training set*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *net size* (jumlah *hidden nodes*)
- Pengaruh faktor *training set* terhadap nilai *MSE* dipengaruhi secara signifikan oleh *net size* (jumlah *hidden nodes*)
- Tidak ada interaksi yang signifikan antara faktor iterasi maksimum dan *training set* dan *net size*


Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.53.



Gambar 4.53. Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* dari pengujian ANOVA untuk material 2 (MLP-GA)


Dari Gambar 4.53 pengaruh faktor *net size* atau jumlah *hidden nodes* menunjukkan semakin banyak jumlah *hidden nodes* akan menghasilkan *MSE* rata-rata yang semakin baik.

Untuk melihat lebih detail pengaruh iterasi maksimum terhadap nilai *MSE* bisa dilihat pada Gambar 4.54, yang menunjukkan perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai *MSE*. Dari plot tersebut terlihat bahwa pengaruh iterasi maksimum terhadap nilai *MSE* menunjukkan perbedaan yang signifikan, dan terlihat bahwa iterasi maksimum 200 menunjukkan akurasi yang paling tinggi sedangkan iterasi maksimum 50 menunjukkan akurasi yang paling rendah.



Gambar 4.54. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai *MSE* untuk material 2 (MLP-GA)

Untuk melihat lebih detail pengaruh *training set* terhadap nilai *MSE* bisa dilihat pada Gambar 4.55, yang menunjukkan perbandingan antara pengaruh *training set* 1, 2 dan 3 terhadap nilai *MSE*. Dari plot tersebut terlihat adanya perbedaan yang signifikan antara *training set* 2 dan *training set* 1 serta *training set* 3 dan *training set* 1. *Training set* 3 dan *training set* 2 tidak menunjukkan perbedaan yang signifikan akan tetapi *training set* 3 menunjukkan mampu menghasilkan nilai *MSE* rata-rata yang lebih rendah. Dan terlihat bahwa *training set* 3 menunjukkan akurasi yang paling tinggi sedangkan *training set* 1 menunjukkan akurasi yang paling rendah.




Gambar 4.55. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai *MSE* untuk material 2 (MLP-GA)

Plot interaksi dari pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.56. Dari plot interaksi antara faktor iterasi maksimum dengan faktor *training set* terlihat pengaruh faktor *training set* konsisten untuk iterasi maksimum 50 dan 100, selain itu pengaruh interaksi faktor iterasi maksimum dan *training set* menunjukkan konsisten dengan pengaruh faktor *training set* tanpa interaksi maupun faktor iterasi maksimum tanpa iterasi. Hal yang berbeda terlihat pada iterasi maksimum 200, dimana pengaruh interaksi faktor iterasi maksimum dan *training set* menunjukkan tidak konsisten dengan pengaruh faktor *training set* tanpa interaksi. Sehingga pengaruh faktor iterasi maksimum terhadap nilai *MSE* dipengaruhi secara signifikan oleh *training set*, begitu juga sebaliknya, pengaruh *training set* terhadap nilai *MSE* rata-rata dipengaruhi secara signifikan oleh iterasi maksimum. Dari plot interaksi tersebut terlihat interaksi antara faktor iterasi maksimum 200 dan *training set* 2 menunjukkan *MSE* rata-rata yang paling rendah.

Dari plot interaksi antara iterasi maksimum dengan *net size* (banyaknya *hidden nodes*) terlihat pengaruh *net size* terhadap iterasi maksimum 50, 100 dan

200 menunjukkan *tend* yang konsisten dengan faktor *net size* tanpa interaksi. Meskipun pada beberapa jumlah *hidden nodes* menunjukkan interaksi yang tidak konsisten dengan faktor iterasi maksimum namun karena jumlahnya yang sedikit sehingga *P-value* menunjukkan nilai diatas 0.05. Dengan demikian pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size*, begitu juga sebaliknya, pengaruh *net size* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Dari plot interaksi tersebut terlihat interaksi antara faktor iterasi maksimum 200 dan jumlah *hidden nodes* yang besar menunjukkan *MSE* rata-rata yang paling rendah.

Dari plot interaksi antara faktor *training set* dengan faktor *net size* terlihat pengaruh faktor *net size* tidak konsisten untuk *training set* 3, selain itu pengaruh interaksi faktor *training set* 3 dan *net size* menunjukkan tidak konsisten dengan pengaruh faktor *net size* tanpa interaksi maupun faktor *training set* tanpa iterasi. Sehingga pengaruh faktor *training set* terhadap nilai *MSE* dipengaruhi secara signifikan oleh *net size*, begitu juga sebaliknya, pengaruh faktor *net size* terhadap nilai *MSE* rata-rata dipengaruhi secara signifikan oleh faktor *training set*. Dari plot interaksi tersebut terlihat interaksi antara *training set* 2 dan jumlah *hidden nodes* yang besar menunjukkan *MSE* rata-rata yang paling rendah. Selain itu *training set* 3 menunjukkan semakin banyak jumlah *hidden nodes* menghasilkan *MSE* rata-rata yang semakin tinggi.



Gambar 4.56. Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* untuk material 2 (MLP-GA)

4.8. Analisa Sensitifitas *Hybrid* MLP-DE

4.8.1. Analisa Sensitifitas Hasil Simulasi Material 1

Tabel hasil uji ANOVA disajikan pada Gambar 4.57.

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Max_iteration	2	0.611	0.30552	7.53	0.001
Train_set	2	2.273	1.13675	28.02	0.000
Net_size	24	1.460	0.06085	1.50	0.055
Max_iteration*Train_set	4	0.191	0.04785	1.18	0.318
Max_iteration*Net_size	48	2.819	0.05873	1.45	0.023
Train_set*Net_size	48	1.655	0.03448	0.85	0.760
Max_iteration*Train_set*Net_size	96	4.242	0.04418	1.09	0.261
Error	6525	264.737	0.04057		
Total	6749	277.989			


Gambar 4.57. Tabel ANOVA hasil pengujian untuk material 1 dengan *MSE* pada tiap percobaan sebagai respon (MLP-DE).

Dengan melihat nilai *P-value* pada tabel ANOVA hasil pengujian, terlihat bahwa:

- Faktor iterasi maksimum berpengaruh secara signifikan terhadap nilai *MSE*.
- Faktor *training set* berpengaruh secara signifikan terhadap nilai *MSE*

- Faktor *net size* (jumlah *hidden nodes*) tidak berpengaruh secara signifikan terhadap nilai *MSE*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *training set*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Pengaruh faktor *training set* terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Tidak ada interaksi yang signifikan antara faktor iterasi maksimum dan *training set* dan *net size*

Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.58.




Gambar 4.58. Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* dari pengujian ANOVA untuk material 1 (MLP-DE)

Dari Gambar 4.58 pengaruh faktor *net size* atau jumlah *hidden nodes* menunjukkan *trend* yang negatif, namun jika dilihat nilainya pada tiap jumlah *hidden nodes*, diduga model korelasinya memiliki residual yang tinggi sehingga

memiliki *P-value* yang lebih besar dari 0.05.


Untuk melihat lebih detail pengaruh iterasi maksimum terhadap nilai *MSE* bisa dilihat pada Gambar 4.59, yang menunjukkan perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai *MSE*. Dari plot tersebut terlihat pengaruh iterasi maksimum 100 berbeda secara signifikan dengan iterasi maksimum 50, dan iterasi maksimum 200 berbeda secara signifikan dengan iterasi maksimum 50. Sebaliknya, iterasi maksimum 200 tidak berbeda secara signifikan dengan iterasi maksimum 100, namun demikian iterasi maksimum 100 menunjukkan akurasi yang lebih baik. Iterasi maksimum 100 menunjukkan akurasi yang paling tinggi sedangkan iterasi maksimum 50 menunjukkan akurasi yang paling rendah.



Gambar 4.59. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai *MSE* untuk material 1 (MLP-DE)

Untuk melihat lebih detail pengaruh *training set* terhadap nilai *MSE* bisa dilihat pada Gambar 4.60, yang menunjukkan perbandingan antara pengaruh *training set* 1, 2 dan 3 terhadap nilai *MSE* rata-rata. Dari plot tersebut terlihat adanya perbedaan yang signifikan antara *training set* 2 dan *training set* 1 serta *training set* 3 dan *training set* 2. *Training set* 3 dan *training set* 1 tidak

menunjukkan perbedaan yang signifikan akan tetapi *training set* 1 menunjukkan mampu menghasilkan nilai *MSE* rata-rata yang lebih rendah. Dan terlihat bahwa *training set* 1 menunjukkan akurasi yang paling tinggi sedangkan *training set* 2 menunjukkan akurasi yang paling rendah.




Gambar 4.60. Plot perbandingan antara pengaruh *training set* 1, 2 dan 3 terhadap nilai *MSE* untuk material 1 (MLP-DE)

Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.61. Dari plot interaksi antara iterasi maksimum dengan *training set* terlihat *trend* perubahan nilai *MSE* rata-rata dari setiap variabel *training set* tidak konsisten dengan *trend* pengaruh iterasi maksimum tanpa interaksi, namun jika melihat perbedaan *MSE* yang tidak signifikan, seperti yang ditunjukkan pada Gambar 4.60, dan terlihat *trend* interaksi antara iterasi maksimum dan *training set* konsisten dengan pengaruh *training set* tanpa interaksi, dengan demikian pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *training set*, begitu juga sebaliknya, pengaruh *training set* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Dari plot interaksi tersebut terlihat interaksi antara faktor iterasi maksimum 100 dan 200 dan *training set* 1 menunjukkan *MSE* rata-rata yang paling rendah. Dengan melihat


Gambar 4.60 terlihat perbedaan yang tidak signifikan antara interaksi *training set* 1 * iterasi maksimum 100 dan interaksi *training set* 1 * iterasi maksimum 200.

Pada plot interaksi antara iterasi maksimum dengan *net size* (banyaknya *hidden nodes*) terlihat bahwa pada beberapa jumlah *hidden nodes* terdapat beberapa grafik yang saling berpotongan dan menunjukkan *trend* yang tidak sama, dan secara statistik ditunjukkan dengan *P-value* yang kurang dari 0.05 yang berarti interaksi tersebut adalah signifikan, sehingga pengaruh faktor iterasi maksimum terhadap nilai *MSE* secara signifikan dipengaruhi jumlah *hidden nodes*.

Pada interaksi antara *training set* dengan *net size*, dimana pengaruh *net size* terhadap training set 1, 2 dan 3 menunjukkan *trend* yang hampir sama, sehingga pengaruh *training set* terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *net size*.



Gambar 4.61. Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* untuk material 1 (MLP-DE)



Gambar 4.62. Plot perbedaan *MSE* rata-rata dari interaksi pengaruh faktor iterasi maksimum dan *training set* untuk material 1 (MLP-DE)

4.8.2. Analisa Sensitifitas Hasil Simulasi Material 2

Tabel hasil uji ANOVA disajikan pada Gambar 4.63.

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Max_iteration	2	0.082	0.04079	2.25	0.106
Train_set	2	16.965	8.48270	467.35	0.000
Net_size	24	1.268	0.05284	2.91	0.000
Max_iteration*Train_set	4	0.036	0.00902	0.50	0.738
Max_iteration*Net_size	48	0.981	0.02043	1.13	0.256
Train_set*Net_size	48	0.789	0.01643	0.91	0.659
Max_iteration*Train_set*Net_size	96	1.977	0.02060	1.13	0.175
Error	6525	118.432	0.01815		
Total	6749	140.530			


Gambar 4.63. Tabel ANOVA hasil pengujian untuk material 2 dengan *MSE* pada tiap percobaan sebagai respon (MLP-DE).

Dengan melihat nilai *P-value* pada tabel ANOVA hasil pengujian, terlihat bahwa:

- Faktor iterasi maksimum tidak berpengaruh secara signifikan terhadap nilai *MSE*.

- Faktor *training set* berpengaruh secara signifikan terhadap nilai *MSE*
- Faktor *net size* (jumlah *hidden nodes*) berpengaruh secara signifikan terhadap nilai *MSE*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *training set*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Pengaruh faktor *training set* terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Tidak ada interaksi yang signifikan antara faktor iterasi maksimum dan *training set* dan *net size*

Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.64.




Gambar 4.64. Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* dari pengujian ANOVA untuk material 2 (MLPDE)

Dari Gambar 4.64 pengaruh faktor *net size* atau jumlah *hidden nodes* menunjukkan semakin banyak jumlah *hidden nodes* akan menghasilkan *MSE*


rata-rata yang semakin besar.

Untuk melihat lebih detail pengaruh iterasi maksimum terhadap nilai *MSE* bisa dilihat pada Gambar 4.65, yang menunjukkan perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai *MSE*. Dari plot tersebut terlihat pengaruh faktor iterasi maksimum tidak menunjukkan perbedaan yang signifikan, namun demikian iterasi maksimum 200 menunjukkan akurasi yang paling tinggi.



Gambar 4.65. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai *MSE* untuk material 2 (MLPDE)

Untuk melihat lebih detail pengaruh *training set* terhadap nilai *MSE* bisa dilihat pada Gambar 4.66, yang menunjukkan perbandingan antara pengaruh *training set* 1, 2 dan 3 terhadap nilai *MSE* rata-rata. Dari plot tersebut terlihat adanya perbedaan pengaruh faktor training set yang signifikan, dan terlihat bahwa *training set* 2 menunjukkan akurasi yang paling tinggi sedangkan training set 3 menunjukkan akurasi yang paling rendah.




Gambar 4.66. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai *MSE* untuk material 2 (MLP-DE)

Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.67. Dari plot interaksi antara faktor iterasi maksimum dengan faktor *training set* terlihat pengaruh faktor *training set* konsisten untuk iterasi maksimum 50, 100 dan 200, selain itu pengaruh interaksi faktor iterasi maksimum dan *training set* menunjukkan konsisten dengan pengaruh faktor *training set* tanpa interaksi. Sehingga pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *training set*, begitu juga sebaliknya, pengaruh *training set* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Gambar 4.68 memperlihatkan perbedaan *MSE* antar interaksi, dan terlihat perbedaan nilai *MSE* pada tiap *training set* menunjukkan perbedaan yang tidak signifikan. Namun demikian interaksi antara iterasi maksimum 200 dan *training set* 2 menunjukkan akurasi yang paling baik.


Dari plot interaksi antara iterasi maksimum dengan *net size* (banyaknya *hidden nodes*) terlihat pengaruh *net size* terhadap iterasi maksimum 50, 100 dan 200 menunjukkan *tend* yang konsisten dengan faktor *net size* tanpa interaksi.

Meskipun pada beberapa jumlah *hidden nodes* menunjukkan plot yang saling berpotongan namun dengan melihat *P-value* yang lebih besar dari 0.05 maka interaksi tersebut tidak signifikan, hal itu diduga karena memiliki perbedaan *MSE* yang tidak signifikan. Dengan demikian pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size*, begitu juga sebaliknya, pengaruh *net size* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Dari plot interaksi tersebut terlihat interaksi antara faktor iterasi maksimum 200 dan jumlah *hidden nodes* yang kecil menunjukkan *MSE* rata-rata yang paling rendah.

Dari plot interaksi antara faktor *training set* dengan faktor *net size* terlihat pengaruh faktor *net size* konsisten semua *training set*, selain itu pengaruh interaksi faktor *training set* dan *net size* menunjukkan konsisten dengan pengaruh faktor *net size* tanpa interaksi maupun faktor *training set* tanpa iterasi. Meskipun pada beberapa jumlah *hidden nodes* menunjukkan plot yang saling berpotongan pada *training set* 1 dan 2 namun dengan melihat *P-value* yang lebih besar dari 0.05 maka interaksi tersebut tidak signifikan, hal itu diduga karena memiliki perbedaan *MSE* yang tidak signifikan. Dengan demikian pengaruh faktor *training set* terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *net size*, begitu juga sebaliknya, pengaruh faktor *net size* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh faktor *training set*. Dari plot interaksi tersebut terlihat interaksi antara *training set* 2 dan jumlah *hidden nodes* yang kecil menunjukkan *MSE* rata-rata yang paling rendah.



Gambar 4.67. Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* untuk material 2 (MLP-DE)



Gambar 4.68. Plot perbedaan *MSE* rata-rata dari interaksi pengaruh faktor iterasi maksimum dan *training set* untuk material 2 (MLP-DE)

4.9. Analisa Sensitifitas *Hybrid* MLP-PSO

4.9.1. Analisa Sensitifitas Hasil Simulasi Material 1

Tabel hasil uji ANOVA disajikan pada Gambar 4.69.

Analysis of Variance


Source	DF	Adj SS	Adj MS	F-Value	P-Value
Max_iteration	2	0.105	0.05255	1.11	0.331
Train_set	2	15.590	7.79501	164.06	0.000
Net_size	24	0.893	0.03723	0.78	0.762
Max_iteration*Train_set	4	0.087	0.02164	0.46	0.768
Max_iteration*Net_size	48	3.248	0.06767	1.42	0.029
Train_set*Net_size	48	2.657	0.05536	1.17	0.203
Max_iteration*Train_set*Net_size	96	4.841	0.05043	1.06	0.323
Error	6525	310.023	0.04751		
Total	6749	337.445			


Gambar 4.69. Tabel ANOVA hasil pengujian untuk material 1 dengan *MSE* pada tiap percobaan sebagai respon (MLP-PSO).

Dengan melihat nilai *P-value* pada tabel ANOVA hasil pengujian, terlihat bahwa:

- Faktor iterasi maksimum tidak berpengaruh secara signifikan terhadap nilai *MSE*.
- Faktor *training set* berpengaruh secara signifikan terhadap nilai *MSE*
- Faktor *net size* (jumlah *hidden nodes*) tidak berpengaruh secara signifikan terhadap nilai *MSE*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *training set*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Pengaruh faktor *training set* terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Tidak ada interaksi yang signifikan antara faktor iterasi maksimum dan *training set* dan *net size*


Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.70.





Gambar 4.71. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai *MSE* untuk material 1 (MLP-PSO)

Untuk melihat lebih detail pengaruh *training set* terhadap nilai *MSE* bisa dilihat pada Gambar 4.72, yang menunjukkan perbandingan antara pengaruh *training set* 1, 2 dan 3 terhadap nilai *MSE* rata-rata. Dari plot tersebut terlihat adanya perbedaan pengaruh faktor training set yang signifikan, dan terlihat bahwa *training set* 3 menunjukkan akurasi yang paling tinggi sedangkan training set 2 menunjukkan akurasi yang paling rendah.




Gambar 4.72. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai *MSE* untuk material 1 (MLP-PSO)

Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.73. Dari plot interaksi antara faktor iterasi maksimum dengan faktor *training set* terlihat pengaruh faktor *training set* konsisten untuk iterasi maksimum 50, 100 dan 200, selain itu pengaruh interaksi faktor iterasi maksimum dan *training set* menunjukkan konsisten dengan pengaruh faktor *training set* tanpa interaksi. Sehingga pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *training set*, begitu juga sebaliknya, pengaruh *training set* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Gambar 4.74 memperlihatkan perbedaan *MSE* antar interaksi, dan terlihat perbedaan nilai *MSE* pada tiap *training set* menunjukkan perbedaan yang tidak signifikan. Namun demikian interaksi antara iterasi maksimum 100 dan 200 dengan *training set* 3 menunjukkan akurasi yang paling baik.


Dari plot interaksi antara iterasi maksimum dengan *net size* (banyaknya *hidden nodes*) terlihat pengaruh *net size* terhadap iterasi maksimum 50, 100 dan 200 menunjukkan banyak sekali plot yang saling berpotongan sehingga pengaruh

interaksinya sangat signifikan. Dari plot tersebut terlihat plot dengan iterasi maksimum 100 dan 200 menunjukkan MSE yang lebih rendah dengan jumlah paling banyak.

Dari plot interaksi antara faktor *training set* dengan faktor *net size* terlihat pengaruh faktor *net size* konsisten semua *training set*, selain itu pengaruh interaksi faktor *training set* dan *net size* menunjukkan konsisten dengan pengaruh faktor *net size* tanpa interaksi maupun faktor *training set* tanpa iterasi. Meskipun pada beberapa jumlah *hidden nodes* menunjukkan plot yang saling berpotongan pada *training set* 1 dan 3 namun dengan melihat P -value yang lebih besar dari 0.05 maka interaksi tersebut tidak signifikan, hal itu diduga karena memiliki perbedaan MSE yang tidak signifikan. Dengan demikian pengaruh faktor *training set* terhadap nilai MSE tidak dipengaruhi secara signifikan oleh *net size*, begitu juga sebaliknya, pengaruh faktor *net size* terhadap nilai MSE rata-rata tidak dipengaruhi secara signifikan oleh faktor *training set*. Dari plot interaksi tersebut terlihat interaksi antara *training set* 3 menunjukkan MSE yang lebih rendah dengan jumlah paling banyak.



Gambar 4.73. Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai MSE untuk material 1 (MLP-PSO)



Gambar 4.74. Plot perbedaan *MSE* rata-rata dari interaksi pengaruh faktor iterasi maksimum dan *training set* untuk material 1 (MLP-PSO)

4.9.2. Analisa Sensitifitas Hasil Simulasi Material 2

Tabel hasil uji ANOVA disajikan pada Gambar 4.75.

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Max_iteration	2	0.297	0.14840	5.66	0.004
Train_set	2	14.006	7.00324	267.08	0.000
Net_size	24	1.929	0.08039	3.07	0.000
Max_iteration*Train_set	4	0.040	0.01012	0.39	0.819
Max_iteration*Net_size	48	1.420	0.02958	1.13	0.252
Train_set*Net_size	48	1.724	0.03591	1.37	0.046
Max_iteration*Train_set*Net_size	96	2.167	0.02257	0.86	0.831
Error	6525	171.095	0.02622		
Total	6749	192.679			

Gambar 4.75. Tabel ANOVA hasil pengujian untuk material 2 dengan *MSE* pada tiap percobaan sebagai respon (MLP-PSO).


Dengan melihat nilai *P-value* pada tabel ANOVA hasil pengujian, terlihat bahwa:

- Faktor iterasi maksimum berpengaruh secara signifikan terhadap nilai *MSE*.
- Faktor *training set* berpengaruh secara signifikan terhadap nilai *MSE*
- Faktor *net size* (jumlah *hidden nodes*) berpengaruh secara signifikan terhadap

nilai *MSE*

- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *training set*
- Pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Pengaruh faktor *training set* terhadap nilai *MSE* dipengaruhi secara signifikan oleh faktor *net size* (jumlah *hidden nodes*)
- Tidak ada interaksi yang signifikan antara faktor iterasi maksimum dan *training set* dan *net size*

Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.76.




Gambar 4.76. Plot pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* dari pengujian ANOVA untuk material 2 (MLP-PSO)

Dari Gambar 4.76 pengaruh faktor *net size* atau jumlah *hidden nodes* menunjukkan semakin banyak jumlah *hidden nodes* akan menghasilkan *MSE* rata-rata yang semakin besar.


Untuk melihat lebih detail pengaruh iterasi maksimum terhadap nilai *MSE*

bisa dilihat pada Gambar 4.77, yang menunjukkan perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai MSE . Dari plot tersebut terlihat pengaruh faktor iterasi maksimum 100-50 menunjukkan perbedaan yang signifikan, sebaliknya pengaruh faktor iterasi maksimum 200-50 dan 200-100 menunjukkan perbedaan yang tidak signifikan. Dari plot tersebut iterasi maksimum 100 menunjukkan akurasi yang paling tinggi.



Gambar 4.77. Plot perbandingan antara pengaruh iterasi maksimum 50, 100 dan 200 terhadap nilai MSE untuk material 2 (MLP-PSO)

Untuk melihat lebih detail pengaruh *training set* terhadap nilai MSE bisa dilihat pada Gambar 4.78, yang menunjukkan perbandingan antara pengaruh *training set* 1, 2 dan 3 terhadap nilai MSE rata-rata. Dari plot tersebut terlihat adanya perbedaan pengaruh faktor training set yang signifikan antara *training set* 3 - *training set* 1 dan *training set* 3 - *training set* 2, sebaliknya *training set* 2 - *training set* 1 menunjukkan perbedaan yang tidak signifikan, dan terlihat bahwa *training set* 2 menunjukkan akurasi yang paling tinggi sedangkan training set 3 menunjukkan akurasi yang paling rendah.




Gambar 4.78. Plot perbandingan antara pengaruh training set 1, 2 dan 3 terhadap nilai *MSE* untuk material 2 (MLP-PSO)

Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* disajikan pada Gambar 4.79. Dari plot interaksi antara faktor iterasi maksimum dengan faktor *training set* terlihat pengaruh faktor *training set* konsisten untuk iterasi maksimum 50, 100 dan 200, selain itu pengaruh interaksi faktor iterasi maksimum dan *training set* menunjukkan konsisten dengan pengaruh faktor *training set* tanpa interaksi. Sehingga pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh *training set*, begitu juga sebaliknya, pengaruh *training set* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Gambar 4.80 memperlihatkan perbedaan *MSE* antar interaksi, dan terlihat perbedaan nilai *MSE* pada tiap *training set* menunjukkan perbedaan yang tidak signifikan. Namun demikian interaksi antara iterasi maksimum 100 dan *training set* 2 menunjukkan akurasi yang paling baik.


Dari plot interaksi antara iterasi maksimum dengan *net size* (banyaknya *hidden nodes*) terlihat pengaruh *net size* terhadap iterasi maksimum 50, 100 dan 200 menunjukkan *tend* yang konsisten dengan faktor *net size* tanpa interaksi. Meskipun pada beberapa jumlah *hidden nodes* menunjukkan plot yang saling

berpotongan namun dengan melihat *P-value* yang lebih besar dari 0.05 maka interaksi tersebut tidak signifikan, hal itu diduga karena memiliki perbedaan *MSE* yang tidak signifikan. Dengan demikian pengaruh faktor iterasi maksimum terhadap nilai *MSE* tidak dipengaruhi secara signifikan oleh faktor *net size*, begitu juga sebaliknya, pengaruh *net size* terhadap nilai *MSE* rata-rata tidak dipengaruhi secara signifikan oleh iterasi maksimum. Dari plot interaksi tersebut terlihat interaksi antara faktor iterasi maksimum 100 dengan jumlah *hidden nodes* yang kecil lebih banyak menunjukkan *MSE* rata-rata yang lebih baik.

Dari plot interaksi antara faktor *training set* dengan faktor *net size* terlihat pengaruh faktor *net size* konsisten semua *training set*, selain itu pengaruh interaksi faktor *training set* dan *net size* menunjukkan konsisten dengan pengaruh faktor *net size* tanpa interaksi maupun faktor *training set* tanpa iterasi. Namun demikian terlihat pada beberapa jumlah *hidden nodes* menunjukkan plot yang saling berpotongan pada *training set* 1 dan 2 dan melihat *P-value* yang lebih kecil dari 0.05 maka interaksi tersebut menjadi signifikan. Dengan demikian pengaruh faktor *training set* terhadap nilai *MSE* dipengaruhi secara signifikan oleh *net size*, begitu juga sebaliknya, pengaruh faktor *net size* terhadap nilai *MSE* rata-rata dipengaruhi secara signifikan oleh faktor *training set*. Dari plot interaksi tersebut terlihat interaksi antara *training set* 2 dengan jumlah *hidden nodes* yang kecil lebih banyak menunjukkan *MSE* rata-rata yang lebih baik.



Gambar 4.79. Plot interaksi pengaruh faktor iterasi maksimum, *training set* dan *net size* (jumlah *hidden nodes*) terhadap nilai *MSE* untuk material 2 (MLP-PSO)



Gambar 4.80. Plot perbedaan *MSE* rata-rata dari interaksi pengaruh faktor iterasi maksimum dan *training set* untuk material 2 (MLP-PSO)

4.10. Perbandingan Kinerja Metode Optimasi GA vs. DE vs. PSO


Pada bagian ini disajikan perbedaan kinerja antara hybrid MLP-GA vs. MLP-DE vs. MLP-PSO. Respon dalam pengujian ini adalah nilai *MSE* pada tiap percobaan dari 30 kali percobaan untuk setiap set parameter. Dasar perhitungan analisa *Tukey test* disajikan di Lampiran 3. Metode tersebut digunakan untuk melihat pengaruh optimasi dengan GA, DE dan PSO untuk material 1 dan 2. Nilai α yang digunakan adalah 0.05 atau tingkat kepercayaan 95%.

Hasil *Tukey simultaneous tests* untuk menguji perbedaan *MSE* rata-rata antara metode optimasi GA, DE dan PSO untuk material 1 disajikan pada Gambar 4.79 dan 4.80. Dari *P-value* yang ditunjukkan pada Gambar 4.81 terlihat bahwa perbedaan kinerja antara metode optimasi menunjukkan perbedaan yang signifikan. Dari perbedaan nilai *MSE* rata-rata yang ditunjukkan pada Gambar 4.82 terlihat bahwa metode optimasi DE menunjukkan kinerja yang paling baik, sementara itu metode optimasi GA menunjukkan kinerja yang paling rendah.

Tukey Simultaneous Tests for Differences of Means

Difference of Optimasi Levels	Difference of Means	SE of Difference	Simultaneous 95% CI	T-Value	Adjusted P-Value
GA - DE	0.10277	0.00363	(0.09428, 0.11127)	28.33	0.000
PSO - DE	0.04707	0.00363	(0.03858, 0.05557)	12.98	0.000
PSO - GA	-0.05570	0.00363	(-0.06419, -0.04721)	-15.35	0.000

Gambar 4.81. Tabel hasil *Tukey simultaneous tests* untuk menguji perbedaan *MSE* rata-rata antara metode optimasi GA, DE dan PSO untuk material 1




Gambar 4.82. Plot hasil *Tukey simultaneous tests* untuk menguji perbedaan *MSE* rata-rata antara metode optimasi GA, DE dan PSO untuk material 1.

Hasil *Tukey simultaneous tests* untuk menguji perbedaan *MSE* rata-rata antara metode optimasi GA, DE dan PSO untuk material 2 disajikan pada Gambar 4.83 dan 4.84. Dari *P-value* yang ditunjukkan pada Gambar 4.83 terlihat bahwa perbedaan kinerja antara metode optimasi menunjukkan perbedaan yang signifikan. Dari perbedaan nilai *MSE* rata-rata yang ditunjukkan pada Gambar 4.84 terlihat bahwa metode optimasi DE menunjukkan kinerja yang paling baik, sementara itu metode optimasi GA menunjukkan kinerja yang paling rendah.

Tukey Simultaneous Tests for Differences of Means

Difference of Optimization Levels	Difference of Means	SE of Difference	Simultaneous 95% CI	T-Value	Adjusted P-Value
GA - DE	0.05096	0.00261	(0.04485, 0.05707)	19.52	0.000
PSO - DE	0.03707	0.00261	(0.03096, 0.04318)	14.20	0.000
PSO - GA	-0.01388	0.00261	(-0.01999, -0.00777)	-5.32	0.000

Gambar 4.83. Tabel hasil *Tukey simultaneous tests* untuk menguji perbedaan *MSE* rata-rata antara metode optimasi GA, DE dan PSO untuk material 2



Gambar 4.84. Plot hasil *Tukey simultaneous tests* untuk menguji perbedaan *MSE* rata-rata antara metode optimasi GA, DE dan PSO untuk material 2.

Beberapa catatan yang didapatkan dari hasil dan analisa di atas antara lain:

1. Pada tesis ini, optimasi untuk mendapatkan nilai bobot NN hanya menggunakan metode metaheuristik murni dan sama sekali tidak digunakan metode gradient, sehingga bisa diketahui kinerjanya secara murni.
2. Metode metaheuristik memiliki keunggulan dalam hal kemudahan algoritma optimasi dimana tidak menggunakan persamaan matematika yang rumit seperti halnya pada metode optimasi menggunakan teknik gradient sehingga lebih mudah diaplikasikan untuk optimasi bobot NN.
3. Beberapa sisi kekurangan dalam menggunakan optimasi metaheuristik murni antara :
 - a) Iterasi atau epoch yang cukup banyak, yang secara umum dengan iterasi 100 atau lebih baru menunjukkan kinerja yang bagus.
 - b) Untuk mendapatkan akurasi yang bagus dibutuhkan jumlah *hidden nodes* yang besar yaitu 25 atau lebih.
 - c) Dari 30 kali percobaan untuk setiap jumlah hidden nodes menghasilkan

akurasi dengan variasi yang kurang baik. Sumber dari variasi tersebut diduga berasal dari populasi awal dengan bilangan random dan juga perbaikan generasi yang melibatkan penggunaan bilangan random, yang dibangkitkan dengan nilai berbeda-beda untuk setiap percobaan.

- d) Dengan mengacu pada point c) di atas, untuk mendapatkan akurasi hasil yang bagus diperlukan beberapa kali percobaan kemudian diambil rata-rata umurnya. Berdasarkan penelitian ini, dengan 30 kali percobaan sudah bisa didapatkan akurasi yang jauh lebih tinggi dibandingkan hasil setiap percobaan.

4.11. Perbandingan Kinerja NN-Metaheuristik Dengan NN-Gradient-Based

Perbandingan akurasi antara model model NN terbaik pada penelitian ini dengan NN-*gradient-based* (Hidayat dkk., 2009) dalam nilai MSE dengan sudut orientasi yang sama (*on-axis*) serta training dan testing set yang sama disajikan pada Tabel 4.24.

Tabel 4.24. Perbandingan Akurasi NN-Metaheuristik Dan NN-Gradient-Based

Material	MLP-GA MSE	MLP-DE MSE	MLP-PSO MSE	NN-Gradient-Based MSE **
#1	*	0.1380	0.1715	0.12
#2	0.2490	0.2445	0.2459	0.23

Catatan:

* Model NN tidak dibandingkan karena menggunakan training dan testing set yang berbeda dengan NN-*gradient-based*

Perbedaan nilai MSE antara model NN-metaheuristik dan NN-*gradient-based* ditampilkan pada Tabel 4.25 dan perhitungan statistik perbedaan nilai MSE tersebut ditampilkan pada Tabel 4.26. Perhitungan statistik pada Tabel 4.26 menggunakan metode *Paired Comparison* (Bhattacharya dkk., 1977). Berdasarkan kesimpulan yang ditunjukkan pada Tabel 4.26, akurasi model NN-metaheuristik pada penelitian ini secara umum *comparable* dengan NN-*gradient-based*, kecuali MLP-PSO pada material 1 yang menghasilkan akurasi yang lebih rendah.

Tabel 4.25. Perbedaan MSE Antara Model NN-Metaheuristik Dan NN-Gradient-Based

Material	Model NN-Metaheuristik	Perbedaan MSE (D)
#1	MLP-DE	0.018
	MLP-PSO	0.0515
#2	MLP-GA	0.019
	MLP-DE	0.0145
	MLP-PSO	0.0159

Tabel 4.26. Perhitungan Statistik Perbedaan Nilai MSE Antara NN-Metaheuristik Dan NN-Gradient-Based

Deskripsi	Rumus	Simbol	Nilai
Rata-rata perbedaan nilai MSE	$\frac{\sum_{i=1}^n D_i}{n}$	\bar{D}	0.0238
Banyaknya data	--	n	5
Standar deviasi D	$\sqrt{\frac{\sum_{i=1}^n (D_i - \bar{D})^2}{n-1}}$	s_D	0.0156
Nilai batas distribusi t (tingkat kepercayaan 95%)	--	$t_{\alpha/2}$	2.7764
Nilai distribusi t	$\frac{D_i - \bar{D}}{s_D / \sqrt{n}}$	t (abs)	MLP-DE #1: 0.829
			MLP-PSO #1: 3.974
			MLP-GA #2: 0.685
			MLP-DE #2: 1.331
			MLP-PSO #2: 1.130
Probablilitas nilai t	Rumus excel: $TDIST(t,n-1,1)$	$P-value$	MLP-DE #1: 0.227
			MLP-PSO #1: 0.008
			MLP-GA #2: 0.265
			MLP-DE #2: 0.127
			MLP-PSO #2: 0.161

Kesimpulan:

Nilai MSE NN-metaheuristik secara umum tidak berbeda secara signifikan dibandingkan NN-gradient-based, kecuali pada MLP-PSO material 1 yang secara signifikan memiliki nilai yang lebih tinggi

BAB 5

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Model NN berbasis MLP dengan satu *hidden layer* dengan algoritma optimasi metaheuristik secara murni untuk memprediksi umur kelelahan komposit berbasis polimer sudah berhasil dikembangkan dengan kesimpulan sebagai berikut:

1. Model NN yang optimal dan efisien untuk material 1 adalah MLP-DE dengan jumlah *hidden nodes* 25-30, dengan iterasi sebanyak 200 kali dan menggunakan contoh data training kombinasi *stress ratio* $R = 0.1$ dan 0.5 . MLP-DE dipilih karena menunjukkan akurasi tertinggi berdasarkan tiga indikator kinerja model NN, yaitu sebanyak 93.75% dari jumlah data prediksi bisa digunakan, serta nilai *MSE* dan R^2 secara berurutan sebesar 0.138 dan 0.9532. Dengan nilai rata-rata R^2 0.9370-0.9532, ketiga model NN dalam penelitian ini menunjukkan akurasi yang tinggi. Model NN yang optimal dan efisien untuk material 2 adalah MLP-GA dengan jumlah *hidden nodes* 25-30, dengan iterasi sebanyak 200 kali dan menggunakan contoh data training kombinasi *stress ratio* $R = 0.1$ dan -1 . MLP-GA dipilih karena menunjukkan jumlah data terbanyak yang bisa digunakan, yaitu 74.76%. Rata-rata *MSE* dan R^2 dari ketiga model NN dalam penelitian ini menunjukkan nilai yang hampir sama, secara berurutan sebesar 0.2445-0.2490 dan 0.8556-0.8575. Ketiga model NN dalam penelitian ini menunjukkan akurasi yang cukup tinggi dengan mempertimbangkan nilai rata-rata R^2 .
2. Dengan indikasi nilai *MSE*, faktor jumlah *hidden nodes*, banyaknya iterasi, contoh data training (*training set*) dan algoritma optimasi metaheuristik secara umum berpengaruh terhadap kinerja model NN. Secara umum semakin banyak jumlah *hidden nodes* menunjukkan akurasi yang semakin baik, kecuali pada MLP-DE untuk material 2, dimana akurasinya naik hingga *hidden nodes* sebanyak 21, dan semakin banyak menunjukkan akurasi yang

lebih rendah. Pengaruh banyaknya iterasi dan *training set* tergantung pada material dan metode optimasi. Dengan demikian, untuk mendapatkan model NN yang optimal maka harus menggunakan faktor jumlah *hidden nodes*, banyaknya iterasi dan contoh data training (*training set*) dengan beberapa variasi. Algoritma optimasi yang terbaik ditunjukkan oleh DE, kemudian dilanjutkan oleh PSO dan GA.

3. Akurasi model NN-metaheuristik pada penelitian ini secara umum *comparable* dengan NN-*gradient-based*, kecuali MLP-PSO pada material 1 yang menghasilkan akurasi yang lebih rendah.

5.2. Saran

Untuk memperbaiki performa model NN dari penelitian ini, penelitian selanjutnya disarankan untuk menambahkan optimasi dengan metode *direct search* atau *gradient base* untuk *refining* nilai bobot dan bias sehingga model NN mampu memiliki generalisasi yang lebih baik. Selain itu juga disarankan untuk menggunakan iterasi maksimum yang lebih banyak dengan interval yang lebih kecil agar lebih diketahui pada iterasi berapa terjadi *overtraining*.

Target yang digunakan pada penelitian ini adalah nilai rata-rata dari umur kelelahan eksperimental pada tiap tingkat tegangan maximum. Penelitian lanjutan disarankan untuk menggunakan nilai rata-rata umur kelelahan berdasarkan kurva *P-S-N* (P, 50%) untuk mengetahui akurasi prediksi NN berdasarkan persentase jumlah data yang bisa digunakan dengan mempertimbangkan kurva *P-S-N* hasil eksperimental yang mengandung *scatter*.

DAFTAR PUSTAKA

- Al-Assaf Y., El-Kadi, H., (2001), "Fatigue life prediction of unidirectional glass fiber/epoxy composite laminae using neural networks," *Composites Structures*, Vol. 53, No. 6, pp. 65-71
- Andersen, S.I., Risø, Bach, P.W., Bonnee, W.J.A., Kensche, C.W., Lilholt, H., Lystrup, A., Sys, W. (1996), "Fatigue of materials and components for wind turbine rotor blades", European Commission, Science Research Development, ISSN 1018-5593
- Anderson, T.L. (2005), "Fracture mechanics: Fundamentals & application, 3rd edition", CRC Press, 2005
- ASTM E 739-91 (2004), "Standard Practice for Statistical Analysis of Linear or Linearized Stress-Life ($S-N$) and Strain-Life ($\epsilon-N$) Fatigue Data".
- Aymerich, F., (2012), "Composite materials for wind turbine blades: Issues and challenges", Department of Mechanical, Chemical and Materials Engineering, University of Cagliari, Italy. In SYSWIND summer school - July 2012 - University of Patras.
- Bezazi, A., Pierce, S.G., Worden, K., Harkati, E.H. (2007), "Fatigue life prediction of sandwich composite materials under flexural tests using a Bayesian trained artificial neural network", *International Journal of Fatigue*, 29(4), 738–747
- Bhattacharya, G.K, Johnson, R.A. (1977), "Statistical Concepts And Methods", John Wiley and Sons, Inc.
- Brøndsted, P., Lilholt, H., Lystrup, A., (2005), 'Composite Materials for Wind Power Turbine Blades', *Annu. Rev. Mater. Res.*, Vol. 35, 2005, pp. 505-538
- Campbell F.C., (2010), "Introduction to Composite Materials", *Structural composite materials*, ASM International
- Chakraborty, A.K. (2008), "Advances in Differential Evolution ", © 2008 Springer-Verlag Berlin Heidelberg
- Cohen, J., (1988), "Statistical Power Analysis for the Behavioral Sciences" Second Edition, LAWRENCE ERLBAUM ASSOCIATES, PUBLISHERS,

Copyright © 1988 by Lawrence Erlbaum Associates

- El-Kadi, H., Al-Assaf, Y., (2002), “Prediction of the fatigue life of unidirectional glass fiber/epoxy composite laminae using different neural network paradigms,” *Composites Structures*, Vol. 55, No. 1, pp. 239-246
- Freire Junior R.C.S., Neto, A.D.D., Aquino, E.M.F. (2005), “Building of constant life diagrams of fatigue using artificial neural networks,” *International Journal of Fatigue*, Vol. 27, No. 7, pp. 746-751
- Freire Junior R.C.S., Neto, A.D.D., Aquino, E.M.F. (2007), “Use of modular networks in the building of constant life diagrams,” *International Journal of Fatigue*, Vol. 29, No. 3, pp. 389-396
- Freire Junior R.C.S., Neto, A.D.D., Aquino, E.M.F. (2009), “Comparative study between ANN models and conventional equations in the analysis of fatigue failure of GFRP,” *International Journal of Fatigue*, Vol. 31, No. 5, pp. 831-839
- Gamstedt, E.K., Talreja, R. (1999), “Fatigue damage mechanisms in unidirectional carbon fibre-reinforced plastics”, *Journal of Materials Science*, no. 34, 1999, pp. 2535-2546
- Haykin S., (2009), “Neural Networks and Learning Machines Third Edition”, Pearson Prentice Hall , Pearson Education, Inc., Upper Saddle River, New Jersey 07458.
- Hidayat, M.I.P., Yusoff, P.S.M.M., (2009), “Optimizing Neural Network Prediction of Composite Fatigue Life Under Variable Amplitude Loading Using Bayesian Regularization “, In *Composite Material Technology: Neural Network Application*, 221-249, USA: CRC Press, Taylor and Francis LLC.
- Jenab, A., Sarraf, I.S, Green, D.E., Rahmaan, T., Worswick, M.J. (2016), “The Use of genetic algorithm and neural network to predict rate-dependent tensile flow behaviour of AA5182-O sheets”, *Materials and Design* 94 (2016) 262-273
- Lazzus, J.A., (2016) “Estimation of the thermal conductivity $k(T,P)$ of ionic liquids using a neural network optimized with genetic algorithms “,

- Comptes Rendus Chimie 19, (2016) 333-341
- Lee, J. A., Almond, D. P., Harris, B. (1999). "The use of neural networks for the prediction of fatigue lives of composite materials". *Composites Part A: Applied Science and Manufacturing* 30:1159–1169
- Lee, J.A., Almond, D.P. (2003). "A neural-network approach to fatigue life prediction. In *Fatigue in composites*", ed. B. Harris, 569–589. Cambridge: Woodhead Publishing.
- Lee, Y.L., Pan, J., Hathaway, R., Barkey, M. (2005). "Fatigue Testing And Analysis: Theory And Practice". Copyright 2005, Elsevier Inc
- Mandell, J.F., Samborsky, D.D., Miller, D.A. (2016), "Analysis of SNL/MSU/DOE Fatigue: Database Trends for Wind Turbine Blade Materials, 2010-2015", SANDIA REPORT SAND SAND2016-1441 Unlimited Release, Printed February 2016, Sandia National Laboratories
- Manshad, A.K., Habib Rostami, H., Hosseini, S.M., Rezaei, H., (2015), "Application of ANN-PSO algorithm for prediction of gas condensate dew point pressure and comparison with GPR-PSO algorithm", *Journal of Energy Resources Technology* (2015), doi:10.1115/1.4032226, Copyright (c) 2015 by ASME
- Marini, F., Walczak, B. (2015), "Particle swarm optimization (PSO): a tutorial", *Chemometrics and Intelligent Laboratory Systems* (2015), doi: 10.1016/j.chemolab.2015.08.020
- Masoud, Y., Khoshraftar, M.M., Fallahi, M. (2013) "A hybrid algorithm for artificial neural network training ", *Engineering Applications of Artificial Intelligence* 26 (2013) 293–301
- Morthorst, P.E., Awerbuch, S., (2009) "The economics of wind energy", a report by the European Wind Energy Association
- Movaghghar, A., Lvovg, I. (2012), "A Method of Estimating Wind Turbine Blade Fatigue Life and Damage using Continuum Damage Mechanics", *International Journal of DAMAGE MECHANICS*, Vol. 21—August 2012
- Nijssen R.P.L., (2007), "Fatigue Life Prediction and strength degradation of wind turbine rotor blade composites", Sandia report no. SAND2006-780P,

unlimited release, Sandia National Laboratories

- Parsopoulos, K.E., Vrahatis, M.N., (2010), "Particle Swarm Optimization and Intelligence: Advances and Applications", Information Science Reference, Hersey - New York, Copyright © 2010 by IGI Global
- Piotrowski, A.P. (2014), "Differential Evolution algorithms applied to Neural Network training suffer from stagnation ", Applied Soft Computing 21 (2014) 382 - 406
- Price, K.V., Storn, R.M., Lampinen, J.A. (2005), "Differential Evolution: A Practical Approach to Global Optimization", © Springer-Verlag Berlin Heidelberg 2005
- Priddy, K.L., Keller, P.E. (2005), "Artificial Neural Networks: And Introduction", SPIE—The International Society for Optical Engineering. Copyright © 2005 The Society of Photo-Optical Instrumentation Engineers
- Samborsky, D.D., Mandell, J.F., Miller, D.D. (2016), "DOE/MSU COMPOSITE MATERIAL FATIGUE DATABASE: Mechanical Properties of Composite Materials for Wind Turbine Blades, Version 25", April 7, 2016, Montana State University - Bozeman
<http://energy.sandia.gov/energy/renewable-energy/wind-power/materials-reliability-standards/>
- Santosa B., Willy, P. (2011), "Metode Metaheuristik: Konsep Dan Implementasi", Edisi pertama, Guna Widya, Surabaya
- Sulistijono (2012), "Mekanika Material Komposit", Edisi pertama, ITS Press, Surabaya
- Vakili, M., Khosrojerdi, S., Aghajannezhad, P., Yahyaei, M. (2017) "A hybrid artificial neural network-genetic algorithm modeling approach for viscosity estimation of graphene nanoplatelets nanofluid using experimental data", International Communications in Heat and Mass Transfer 82 (2017) 40-48
- Vassilopoulos, A.P., Georgopoulos, E.F., Dionysopoulos, D., (2007), "Artificial neural networks in spectrum fatigue life prediction of composite materials", International Journal of Fatigue, Vol. 29, No. 3, pp. 20-29]
- Xiang, K.L., Xiang, P.Y., Y.P., (2014), "Prediction of the fatigue life of natural

rubber composites by artificial neural network approaches”, *Materials and Design* 57 (2014) 180-185

Zhang Z., K. Friedrich, (2003), “Artificial neural networks applied to polymer composites: a review“, *Composites Science and Technology* 63 (2003) 2029–2044

(Halaman ini sengaja dikosongkan)

LAMPIRAN 1

Review Data Kelelahan Komposit **Sandia National Laboratories / Montana State University /** **Department of Energy (SNL/MSU/DOE)**

1. Pendahuluan

Bilah turbin angin dirancang dengan mempertimbangkan beberapa kondisi utama pada suatu struktur, termasuk di dalamnya adalah defleksi ujung bilah, kekuatan dan buckling selama pembebanan yang parah, umur siklus kelelahan yang panjang dan beberapa kondisi lingkungannya.

MSU Database Program sudah dimulai sejak tahun 1989, melakukan pengkajian komposit untuk menyediakan properties yang luas. Pengkajian komposit dilakukan terhadap material yang sudah banyak digunakan dan juga mencari material yang potensial. Dalam pelaksanaan pengujian dan pengembangan material, Montana State University (MSU) bekerja sama dengan Sandia National Laboratories (SNL), wind industry, dan beberapa rekanan untuk menyediakan material.

Hingga saat ini, MSU sudah merilis untuk umum sebuah database data kelelahan komposit hingga versi ke-25, dimana datanya bisa diunduh pada alamat <http://energy.sandia.gov/energy/renewable-energy/wind-power/materials-reliability-standards/>.

2. Pengujian Material Yang Sudah Dikembangkan SNL/MSU/DOE

Pengujian material komposit yang sudah dikembangkan oleh SNL/MSU/DOE menggunakan *resin* dan serat seperti yang ditunjukkan pada Tabel L1.1 dan Tabel L1.2.

Tabel L1.1. Material Resin Yang Telah Digunakan Untuk Penelitian Komposit Yang Sudah Dikembangkan Oleh SNL/MSU/DOE (Samborsky dkk., 2016)

Name	Type	Resin	Cure and Post Cure Temperature, °C
EP-1	Epoxy	Hexion MGS RIMR 135/MGS RIMH 1366	24h/20C, 12h/90C
EP1a	Epoxy	Hexion MGS RIMR 135/MGS RIMH 1366	24h/35C, 12h/70C
EP-2	Epoxy	Vantico TDT 177-155	24h/20C, 8h/70C
EP-3	Epoxy	SP Systems/Gurit Prime 20LV, with slow hardener	24h/20C, 16h/50C

LAMPIRAN 1

EP-4	Epoxy	Huntsman Araldite LY1564/XB3485	60C and 82C
EP-5	Epoxy	Hexion RIMR135 / RIMH137	24h/20C, 8h/70C
EP-6	Epoxy	Jeffco 1401-12/4101-17	24h/20C, 14h/60C, 2h/85C
EP-7	Epoxy	DOW un-toughened epoxy	24h/20C, 12h/90C
EP-8	Epoxy	DOW toughened epoxy	24h/20C, 12h/90C
EP-9	Epoxy	Hexion RIMR 035C/ RIMH 037	6h/70 C
EP-10	Epoxy	Hexion RIMR 145/RIMH 145/ RIMC 145 (100:82:0.3 by wt)	Infused at 80C, ramped up to 120C in 40 minutes, held 4 hours, cooled to 80C and held for 8 hours
UP-1	Polyester	U-Pica/Hexion TR-1 with 1.5% MEKP	24h/20C, 12h/90C
UP-2	Polyester	CoRezyn 63-AX-051 with 1% MEKP	6h/20C, 2h/60 C
UP-3	Polyester	Ashland AROPOL 1101-006 LGT with 1.5% DDM-9 MEKP	Unspecified / 3h/65C
UP-4	Polyester	CoRezyn 75-AQ-010 with 2.0% MEKP	6h/20C, 2 h/60 C
UP-5	Polyester	Reichhold Polylyte X4627-31	24h/25C, 12h/70C
VE-1	Vinyl ester	Ashland Derakane Momentum 411-350 with 0.1% CoNap, 1% MEKP and 0.02 phr 2,4-Pentanedione	24h/20C, 2h/100C
VE-2	Vinyl ester	Ashland Derakane 8084 with 0.3% CoNap and 1.5% MEKP	24h/20C, 12h/90C
VE2a	Vinyl ester	Ashland Derakane 8084 with 6% ETBN	24h/20C, 12h/90C
VE-3	Vinyl ester	Ashland Derakane 411-200	Not specified
VE-4	Vinyl ester	Reichhold Dion X4486-14	24h/25C, 12h/70C
VE-5	Vinyl ester	Reichhold Dion X4235-91	24h/35C, 12h/70C
VE-6	Vinyl ester	Reichhold Dion X4627-39	24h/25C, 12h/70C
VE-7	Vinyl ester	Ashland 601-200	24h/25C, 12h/70C

Tabel L1.2. Material Serat Yang Telah Digunakan Untuk Penelitian Komposit Oleh SNL/MSU/DOE (Samborsky dkk., 2016)

	Fabric Manufacturer	Designation	Areal Wt. (g/m ²)	Component Strands Warp Dir.(wt.%)				
				0°	±45°	90°	Mat	Stitch
A	Knytex	D155 (E-Glass)	527	0	0	99	0	1
B	Saertex	U14EU920-00940-T1300-100000 (E-Glass)	955	91	0	8	0	1
C	Saertex	S15EU980-01660-T1300-088000 (E-Glass)	1682	97	0	2	0	1
D	Vectorply	E-LT-5500 (E-Glass)	1875	92	0	6	0	2
E	Vectorply	E-LM-1810 (E-Glass)	932	67	0	0	32	1
F	Vectorply	E-LM-3610 (E-Glass)	1515	80	0	0	20	0
G	Vectorply	E-LM-3900 (E-Glass)	1346	90	0	9	0	1
H	PPG-Devold LLC	L1200/G50-E07 (E-Glass)	1261	91	0	4	4	1
I	OCV	1000UD (Glass Fiber)	985	96	0	2	0	2
J	OCV	1200UD (Glass Fiber)	1150	95	0	4	0	1
K	OCV	1322UD (Glass Fiber)	1450	95	0	4	0	1

LAMPIRAN 1

L	Saertex	VU-90079-00830-01270-000000 (E-Glass)	831	0	97	2	0	1
M1	Fiber Glass Ind.	SX-1708 (Glass Fiber)	857	0	68	0	30	2
M2	Knytex	DBM-1708 (E-Glass)	857	0	68	0	30	2
N	Vectorply	E-BX-1700 (E-Glass)	608	0	99	0	0	1
O	OCV	WindStrand DB1000 (Glass Fiber)	1000	5	94	0	0	1
P	PPG-Devold LLC	DB810-E05-A (E-Glass)	808	0	99	0	0	1
Q	Knytex	DB240 (E-Glass)	837	0	98	0	0	2
R	Saertex	MMWK Triax, Glass/carbon/glass	970	69	31	0	0	NA
S	Toray	ACM-13-2 carbon (300-48k-10C yarn)	600	100	0	0	0	NA

3. Material Bilah Turbin Angin

Material komposit yang umum digunakan untuk bilah turbin angin adalah jenis *fibres reinforced polymer*, karena material tersebut memiliki nilai kekakuan yang tinggi, rasio *stiffness-to-density* yang tinggi dan *fracture toughness* yang tinggi.

Polymer jenis *thermoset* lebih disukai dibandingkan *thermoplastic*, karena faktor kemudahan dalam fabrikasi. *Polymer* jenis *thermoplastic* memiliki kekurangan dalam hal fabrikasi yaitu harus dengan temperatur dan tekanan yang tinggi sehingga cukup menjadi kesulitan dalam proses fabrikasi, diantaranya adalah membutuhkan peralatan atau mesin yang lebih rumit dan membutuhkan energi yang lebih tinggi.

Dari sisi sifat kelelahan, komposit dengan matriks *thermoset* memiliki performa yang lebih tinggi dibandingkan komposit dengan matriks *thermoplastic* (Gamstedt, dkk., 1999).

Resin jenis *thermoset polymer* yang paling banyak digunakan untuk matriks bilah turbin angin adalah *epoxy*, *polyester* dan *vinylester*, alasan utama penggunaan ketiga resin tersebut adalah karena faktor kemudahan dalam pemrosesan atau fabrikasi komposit karena viskositas yang rendah (Mallick, 2007).

Karena alasan harga yang cukup murah dan paling banyak tersedia di pasaran, serat jenis *E-glass* adalah yang paling banyak digunakan sebagai penguat dari komposit. Namun akhir-akhir ini telah tersedia juga serat jenis

LAMPIRAN 1

H-glass (hollow-glass) yang lebih murah dan memiliki *stiffness* yang lebih tinggi dibandingkan dengan E-glass, yaitu 82-86 GPa. (Brøndsted, dkk., 2013).

Selain jenis *glass fibers*, *carbon fibers* juga digunakan sebagai penguat komposit untuk material bilah turbin angin, dimana memiliki keunggulan dibandingkan *glass fibers* dalam hal density (2/3 kali lebih rendah dari *glass fibers*), modulus elastisitas, kekuatan tarik (beberapa material *carbon fibers* memiliki *tensile strength* yang lebih rendah dari *glass fibers*. Lihat Tabel L1.3) dan ketahanan terhadap kelelahan, namun demikian *carbon fibers* masih jarang digunakan untuk konstruksi dan masih dalam tahap riset karena memiliki harga yang relatif masih tinggi (Tong, 2010).

Tabel L1.3. *Properties* dari Beberapa *Reinforcing fibers* Jenis *Glass fibers* dan *Carbon fibers* (Mallick, 2007)

Fiber	Typical Diameter (μm) ^a	Density (g/cm ³)	Tensile Modulus GPa (Msi)	Tensile Strength GPa (ksi)	Strain-to-Failure (%)	Coefficient of Thermal Expansion (10 ⁻⁶ /°C) ^b	Poisson's Ratio
<i>Glass</i>							
E-glass	10 (round)	2.54	72.4 (10.5)	3.45 (500)	4.8	5	0.2
S-glass	10 (round)	2.49	86.9 (12.6)	4.30 (625)	5.0	2.9	0.22
<i>PAN carbon</i>							
T-300 ^c	7 (round)	1.76	231 (33.5)	3.65 (530)	1.4	-0.6 (longitudinal) 7-12 (radial)	0.2
AS-1 ^d	8 (round)	1.80	228 (33)	3.10 (450)	1.32		
AS-4 ^d	7 (round)	1.80	248 (36)	4.07 (590)	1.65		
T-40 ^e	5.1 (round)	1.81	290 (42)	5.65 (820)	1.8	-0.75 (longitudinal)	
IM-7 ^d	5 (round)	1.78	301 (43.6)	5.31 (770)	1.81		
HMS-4 ^d	8 (round)	1.80	345 (50)	2.48 (360)	0.7		
GY-70 ^e	8.4 (bilobal)	1.96	483 (70)	1.52 (220)	0.38		
<i>Pitch carbon</i>							
P-55 ^c	10	2.0	380 (55)	1.90 (275)	0.5	-1.3 (longitudinal)	
P-100 ^c	10	2.15	758 (110)	2.41 (350)	0.32	-1.45 (longitudinal)	

4. Dasar-dasar Material Komposit

4.1. Material

Komposit didefinisikan sebagai suatu material yang terdiri dari dua atau lebih komponen penyusunnya yang memiliki sifat atau struktur yang berbeda yang dicampur secara fisik menjadi satu dan membentuk ikatan mekanik, yang memiliki struktur yang homogen secara makroskopik dan heterogen secara mikroskopik. Material campuran tersebut memiliki sifat yang lebih baik dari material penyusunnya.


Komposit tersusun dari dua atau lebih material dengan fase yang berbeda. Fase diskontinyu memiliki kekuatan dan kekakuan yang lebih tinggi disebut sebagai penguat (*reinforcing material*) dan fase kontinyu yang berfungsi untuk

LAMPIRAN 1

mengikat material penguat, menyebarkan beban ke material penguat, memberi bentuk, melindungi dari pengaruh lingkungan (kelembaban dan kimia) serta degradasi mekanikal (misalnya abrasi), disebut sebagai matriks. Dalam hal perannya untuk menahan beban tarik, matriks memiliki peran yang relatif kecil dibandingkan dengan material penguat sehingga sebagian besar beban tarik ditanggung oleh material penguat. Dalam hal pembebanan kompresi, matriks memiliki peran yang dominan karena kemampuannya untuk menahan material penguat untuk mencegah terjadinya *buckling* (Mallick, 2007).

4.2. Struktur Laminat

Sebuah struktur laminat tersusun atas beberapa lamina yang disusun pada arah tebal komposit, secara ilustratif ditunjukkan pada Gambar L1.1.

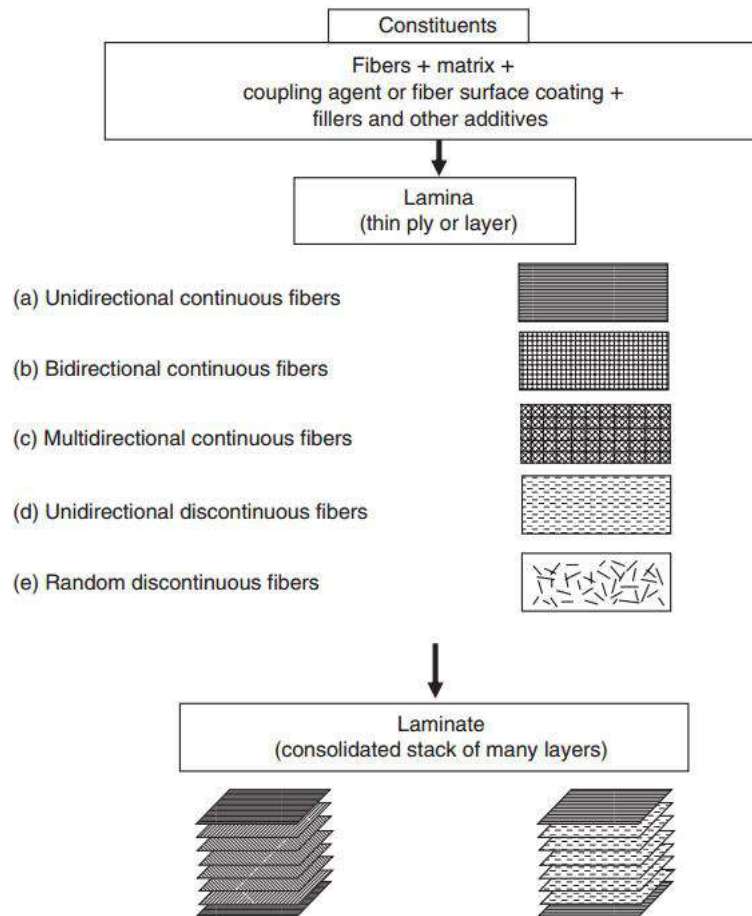


Gambar L1.1. Susunan lamina penyusun laminat.

Sebuah lamina tersusun atas material penguat (serat), matriks, *coupling agent* atau *fiber surface coating*, *filler*, dan *material additives*. Sebuah lamina bisa tersusun atas satu jenis serat dengan arah serat yang seragam atau gabungan dari beberapa serat dengan arah yang bervariasi. Sebuah laminat tersusun dari beberapa lamina dalam bentuk *interply* atau *intraply hybrid laminate*. Sebuah *interply hybrid laminate* tersusun dari beberapa lamina dimana setiap lamina tersusun dari serat dengan jenis yang sama, sedangkan *intraply hybrid laminate* tersusun dari beberapa lamina dimana setiap lamina tersusun dari dua atau lebih serat dengan jenis yang sama. Semua lamina yang tersusun dalam sebuah laminat memiliki matrik dengan material yang sama sehingga terbentuk

LAMPIRAN 1

interlaminar bond yang seragam. Secara umum, susunan dari sebuah lamina ditunjukkan pada Gambar L1.2.




Gambar L1.2. Susunan di dalam *fiber-reinforced composites* (Mallick, 2007)

Sudut Arah Orientasi Serat

Aturan penulisan sudut arah orientasi serat adalah: sudut positif adalah sudut arah berlawanan arah putaran jarum jam terhadap arah sumbu referensi, sebaliknya, sudut negatif adalah sudut arah searah dengan arah putaran jarum jam terhadap arah sumbu referensi. Arah sumbu referensi adalah 0° , yang merupakan arah *axial load*. Lihat Gambar L1.3.

LAMPIRAN 1




GAMBAR L1.3. Aturan sudut arah orientasi serat (Harper dkk., 2003)

Aturan Penulisan Susunan Lamina


Beberapa contoh susunan laminat yang utama adalah seperti berikut (Mallick, 2007):

1. **Unidirectional laminate**: sudut orientasi serat sama untuk semua lamina. Contoh susunan unidirectional adalah $\theta = 0^\circ$ untuk semua lamina, $\theta = 45^\circ$ untuk semua lamina. Contoh susunan orientasi serat seperti Gambar L1.4.



Gambar L1.4. (a) *Unidirectional laminate* dengan arah serat seragam 0° , dikodekan dengan (0/0/0). (b) *Unidirectional laminate* dengan arah serat seragam 45° , dikodekan dengan [45/45/45]


2. **Angle-ply laminate**: sudut orientasi serat berlawanan arah untuk setiap pergantian layer: $\theta / -\theta / \theta / -\theta$. ($\theta \neq 0^\circ$ atau 90°). Contoh susunan orientasi serat seperti Gambar L1.5.



Gambar L1.5. *Angle-ply laminate* dengan arah serat $+45^\circ$, -45° , $+45^\circ$, -45° , dikodekan dengan $[\pm 45_2]$.


LAMPIRAN 1

3. **Cross-ply laminate:** sudut orientasi serat untuk setiap pergantian layer adalah $0^\circ / 90^\circ / 0^\circ / 90^\circ$. Contoh sususunan orientasi serat seperti Gambar L1.6.



Gambar L1.6. *Cross-ply laminate* dengan arah serat $90^\circ, 0^\circ, 90^\circ, 0^\circ$, dikodekan dengan $[0/90/0/90]$.

4. **Symmetric laminate:** Lamina tersusun dengan arah orientasi yang simetri, yang berpusat pada *center line* laminat (C/L); sehingga tiap lamina di atas C/L laminat memiliki *properties* yang sama dengan lamina di bawah C/L laminat (material, tebal dan sudut orientasi serat). Dengan demikian, untuk *symmetrical laminate* berlaku $\theta(z) = \theta(-z)$, dimana θ adalah sudut orientasi serat, dan z adalah jarak dari C/L laminat. Contoh sususunan orientasi serat seperti Gambar L1.7.



Gambar L1.7. *Symmetric laminate* dengan arah serat $0^\circ, +45^\circ, -45^\circ, 90^\circ, 90^\circ, -45^\circ, +45^\circ, 0^\circ$; dikodekan dengan $[0/\pm 45/90]_s$. *Subscript S* adalah menunjukkan bahwa laminat simetri terhadap referensi C/L laminat.

Beberapa contoh symmetric laminate beserta pengkodeannya adalah sebagai berikut:

- Susunan lamina: $[0/+45/90/90/+45/0]$
Kode : $[0/45/90]_s$
- Susunan lamina: $[0/+45/90/+45/0]$
Kode : $[0/45/\overline{90}]_s$

LAMPIRAN 1

Tanda *bar* di atas 90 menunjukkan bahwa *center* dari laminat adalah di *center* pada lamina orientasi serat 90°.

- Susunan lamina: $[0/+45/-45/90/-45/+45/0]$
Kode : $[0/\pm 45/\overline{90}]_s$
 - Susunan lamina: $[0/90/0/0/0/0/45/45/0/0/0/0/90/0]$
Kode : $[0/90/0_4/45]_s$
 - Susunan lamina: $[0/+45/-45/+45/-45/-45/+45/-45/+45/0]$
Kode : $[0/(\pm 45)_2]_s$
 - Susunan lamina:
 $[0/+45/-45/+45/-45/+45/-45/0/0/0/0/-45/+45/-45/+45/-45/+45/0]$
Kode : $[0/(\pm 45)_3/0_2/\overline{0}]_s$
 - Susunan lamina: $[+45/-45/+45/-45/-45/+45/-45/+45]$
Kode : $[+45/-45]_{2s}$ atau $[\pm 45]_{2s}$
 - *Symmetric angle-ply laminate:*
Susunan lamina: $[+45/-45/+45/-45/+45/-45/+45]$
Kode : $[\pm 45/+45/-\overline{45}]_s$
 - *Symmetric cross-ply laminate:*
Susunan lamina: $[0/90/0/90/0/90/0/90/0]$
Kode : $[(0/90)_2/\overline{0}]_s$
 - *Hybrid (interply) laminate:*
Susunan lamina: $[0_B/0_B/+45_C/-45_C/90_G/90_G/-45_C/+45_C/0_B/0_B]$
Kode : $[0_{2B}/(\pm 45)_C/90_G]_s$
Dimana B, C, G secara berurutan menunjukkan jenis serat *boron*, *carbon*, dan *glass fiber*.
5. ***Antisymmetric laminate:*** orientasi lamina adalah antisimetri terhadap C/L laminat, jika di atas C/L laminat sudut orientasi suatu lamina adalah θ , maka sudut orientasi serat suatu lamina di bawah C/L laminat dengan jarak yang sama adalah $-\theta$. Sehingga sudut orientasi serat pada antisymmetric laminate adalah: $\theta(z) = -\theta(-z)$.

LAMPIRAN 1

6. ***Unsymmetric laminate***: pada *unsymmetric laminate*, tidak ada susunan yang simetru ataupun antisimetri.

Contoh: [0/0/0/90/90/90]

7. ***Quasi-isotropic laminate***: laminat jenis ini tersusun dari tiga atau lebih lamina yang memiliki ketebalan dan material yang sama, dengan perbedaan sudut yang seragam antara satu lamina dengan lamina urutan berikutnya. Jika jumlah total lamina adalah n , maka sudut orientasi serat untuk tiap lamina berurutan dengan *increment* π/n , sehingga laminat mempunyai *properties* yang hampir *isotropic* pada bidang x - y . Misal, $n = 4$, maka sudut orientasi tiap lamina berbeda dengan *increment* $180^\circ/4 = 45^\circ$; contoh susunan lamina: [+45/0/-45/90].

Contoh lain:

$n = 3$: [+60/0/-60]

5. Interaksi *Fiber-Matrix* Pada *Unidirectional Lamina* (mekanika-mikro)

Untuk memprediksi kekakuan (*stiffness*) dan kekuatan (*strength*) dari suatu lamina harus mempertimbangkan faktor serat penguat dan material matriksnya, sehingga kekakuan dan kekuatan suatu komposit ditentukan oleh interaksi antara volume serat penguat dan matriks, kekuatan serat penguat dan matriks serta kekakuan serat penguat dan matriks.

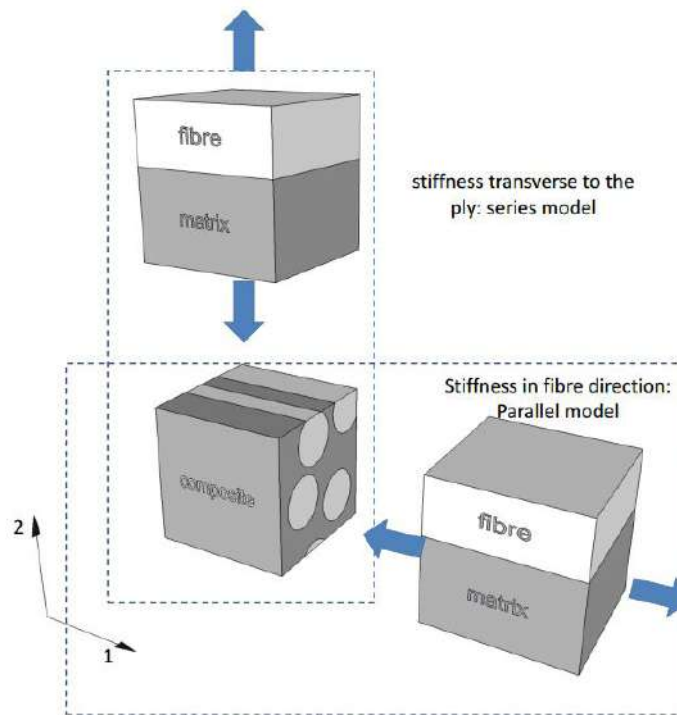
Untuk mempelajari interaksi antara *fiber-matrix* maka harus didekati dengan beberapa asumsi, yaitu (Mallick, 2007):

1. Serat terdistribusi secara merata di dalam matriks.
2. *Bonding* antara serat dan matrix dianggap sempurna.
3. Tidak terdapat *voids* di dalam *matrix*.
4. Gaya yang bekerja adalah paralel atau normal terhadap arah serat.
5. Awalnya lamina berada pada kondisi tanpa tegangan dan tidak ada tegangan sisa.
6. Baik serat maupun *matrix* dianggap sebagai *linearly elastic materials*.

LAMPIRAN 1

5.1. Longitudinal Tensile Loading untuk Unidirectional Continuous Fibers

Analisa kekakuan komposit dibedakan menjadi dua model, yaitu model paralel dan model seri. Model paralel digunakan untuk memprediksi kekakuan komposit pada arah yang searah dengan arah serat, sedangkan model seri digunakan untuk memprediksi kekakuan komposit pada arah yang tegak-lurus (beban transversal) terhadap arah serat. Untuk mempermudah pemahaman, model paralel dan seri diilustrasikan pada Gambar L1.8.



Gambar L1.8. Model paralel dan model seri untuk menggambarkan kekakuan komposit pada arah yang berbeda (Nijssen, 2015).

5.1.1. Kekakuan Model Paralel

Jika diasumsikan bahwa terjadi *bonding* yang sempurna antara serat dan matriks, maka:

$$\varepsilon_f = \varepsilon_m = \varepsilon_c \quad (1)$$

Dimana ε , c , f , m secara berurutan adalah notasi untuk *strain*, *composite*, *fiber*, dan *matrix*.

LAMPIRAN 1


Jika diasumsikan baik serat maupun *matrix* adalah elastis, maka:

$$\sigma_f = E_f \cdot \varepsilon_f = E_f \cdot \varepsilon_c \quad (2)$$

$$\sigma_m = E_m \cdot \varepsilon_m = E_m \cdot \varepsilon_c \quad (3)$$

Dimana σ dan E secara berurutan adalah notasi untuk tegangan dan kekakuan (*stiffness*).

Karena $E_f > E_m$, maka tegangan serat (σ_f) selalu lebih tinggi dari tegangan matrix (σ_m), seperti yang ditunjukkan pada Gambar L1.9.



Gambar L1.9. *Longitudinal tensile loading* pada *unidirectional continuous fiber lamina*, dimana σ_{fu} adalah *ultimate tensile strength* serat, σ_{ctu} adalah *ultimate tensile strength* lamina atau komposit, dan σ_{mu} adalah *ultimate tensile strength* dari *matrix* (Mallick, 2007).

Jika beban tarik lamina (P_c) dibagikan ke serat (P_f) dan matriks (P_m), atau

$$P_c = P_f + P_m, \quad (4)$$

Maka:

$$\sigma_c \cdot A_c = \sigma_f \cdot A_f + \sigma_m \cdot A_m \quad (5)$$

Dimana A_c , A_f dan A_m secara berurutan adalah luasan lamina, serat dan *matrix*.

LAMPIRAN 1

Dari persamaan 5, tegangan rata-rata lamina (σ_c) bisa ditulis dengan persamaan:

$$\sigma_c = \sigma_f \cdot \frac{A_f}{A_c} + \sigma_m \cdot \frac{A_m}{A_c} \quad (6)$$

Dianggap perbandingan antara volume serat (V_f) terhadap volume lamina (V_c) sama dengan perbandingan antara luas penampang serat (A_f) terhadap luas penampang lamina (A_c):

$$\frac{V_f}{V_c} = \frac{A_f}{A_c} \quad (7)$$

Dimana V_f/V_c adalah *viber volume fraction* (v_f).

Jika $v_f + v_m = 1$, dimana v_m adalah *matrix volume fraction*, maka $v_m = 1 - v_f$, atau $v_m = A_m/A_c$, maka tegangan rata-rata lamina (σ_c) pada persamaan 6 bisa ditulis dengan:

$$\sigma_c = \sigma_f \cdot v_f + \sigma_m \cdot (1 - v_f) \quad (8)$$

Jika kedua sisi pada persamaan 8 dibagi dengan ε_c (*strain* lamina) didapatkan persamaan:

$$\frac{\sigma_c}{\varepsilon_c} = \frac{\sigma_f}{\varepsilon_c} \cdot v_f + \frac{\sigma_m}{\varepsilon_c} \cdot (1 - v_f) \quad (9)$$

Dengan menggunakan persamaan 1, yaitu $\varepsilon_f = \varepsilon_m = \varepsilon_c$, maka persamaan 9 bisa ditulis dengan persamaan:

$$\frac{\sigma_c}{\varepsilon_c} = \frac{\sigma_f}{\varepsilon_f} \cdot v_f + \frac{\sigma_m}{\varepsilon_m} \cdot (1 - v_f) \quad (10)$$

Jika diasumsikan baik serat, *matrix* dan lamina adalah elastis, maka didapatkan hubungan antara kekakuan (*stiffness*) lamina (E_c) dengan kekakuan serat (E_f) dan

LAMPIRAN 1

kekakuan *matrix* (E_m) untuk pembebanan longitudinal pada *unidirectional continuous fiber* adalah:

$$E_c = E_f \cdot v_f + E_m(1 - v_f) = E_m + v_f(E_f - E_m) \quad (11)$$

Untuk mendapatkan nilai *fiber volume fraction* dari suatu lamina yang dikehendaki dengan nilai kekakuan = E_c , maka bisa menggunakan persamaan 12 yang disusun berdasarkan persamaan 11, yaitu:

$$v_f = \frac{(E_c - E_m)}{(E_f - E_m)} \quad (12)$$

Dari persamaan 11 terlihat bahwa kekakuan lamina atau komposit dengan *unidirectional continuous fiber* pada pembebanan longitudinal berbanding lurus dengan *fiber volume fraction*, semakin besar *fiber volume fraction* maka semakin tinggi kekakuannya. Namun kenyataannya, hubungan tersebut tidak selalu benar, pada prakteknya *fiber volume fraction* dibatasi maksimum sekitar 80% karena jika lebih dari resin tidak dapat membasahi semua serat sehingga terdapat cacat di dalam lamina atau komposit.


5.1.2. Kekuatan Tarik Lamina Model Paralel

Dari Gambar L1.9 terlihat bahwa *ultimate tensile strength* dari lamina (σ_{Ltu}) terjadi pada saat *ultimate strain* dari serat (ϵ_{fu}). Ultimate tensile strength lamina dirumuskan dengan (Mallick, 2007):

$$\sigma_{Ltu} = \sigma_{fu} \cdot v_f + \sigma'_m(1 - v_f) \quad (13)$$

Dimana σ'_m adalah tegangan *matrix* saat mengalami regangan sama dengan *ultimate strain* dari serat (ϵ_{fu}), σ_{fu} adalah *ultimate tensile strength* serat dan v_f adalah *fiber volume fraction*.

LAMPIRAN 1



Gambar L1.10. *Longitudinal tensile strength* yang nilainya bervariasi dengan *fiber volume fraction* pada *unidirectional continuous fiber composite* dengan *matrix failure strain* lebih besar dari *fiber failure strain*. (Mallick, 2007).

Dari Gambar L1.10 terlihat bahwa terdapat nilai *critical fiber volume fraction* dimana jika *fiber volume fraction* kurang dari nilai *critical* tersebut maka besarnya *ultimate tensile strength* dari lamina (σ_{Ltu}) lebih rendah dari *ultimate tensile strength* dari matrix (σ_{mu}).

Nilai *critical fiber volume fraction* adalah:

$$\text{Critical } v_f = \frac{\sigma_{mu} - \sigma'_m}{\sigma_{fu} - \sigma'_m} \quad (14)$$

Tabel L1.4. Contoh Nilai *Critical v_f* Dari Serat *E-glass* Dan Serat *Carbon* Dengan *Matrix Epoxy*^a (Mallick, 2007)

Property	E-Glass Fiber	Carbon Fiber
E_f	10×10^6 psi	30×10^6 psi
σ_{fu}	250,000 psi	400,000 psi
$\varepsilon_{fu} = \frac{\sigma_{fu}}{E_f}$	0.025	0.0133
$\sigma'_m = E_m \varepsilon_{fu}$	2,500 psi	1,330 psi
Critical v_f	3.03%	2.17%

^a Matrix properties: $\sigma_{mu} = 10,000$ psi, $E_m = 0.1 \times 10^6$ psi, and $\varepsilon_{mu} = 0.1$.

LAMPIRAN 1

5.2. Transversal Tensile Loading untuk Unidirectional Continuous Fibers

Estimasi nilai kekakuan lamina dengan *transversal tensile loading* (E_T) untuk *unidirectional continuous fibers* adalah (Mallick, 2007):

$$\frac{1}{E_T} = \frac{\nu_f}{E_f} + \frac{\nu_m}{E_m} \quad (15)$$

Atau

$$E_T = \frac{E_f \cdot E_m}{E_f \cdot \nu_m + E_m \cdot \nu_f} = \frac{E_f \cdot E_m}{E_f - \nu_f (E_f - E_m)} \quad (16)$$

Estimasi nilai *transverse tensile strength* (σ_{Ttu}) dari *unidirectional continuous fibers* adalah (Mallick, 2007):

$$\sigma_{Ttu} = \frac{\sigma_{mu}}{K_\sigma} \quad (17)$$

Dimana:

$$K_\sigma = \frac{1 - \nu_f [1 - (E_m / E_f)]}{1 - (4\nu_f / \pi)^{1/2} [1 - (E_m / E_f)]} \quad (18)$$

Tabel L1.5. Contoh Efek *Transverse Loading* Pada *Unidirectional Composite* (Mallick, 2007)

Composite Material	$\frac{E_f}{E_m}$	ν_f (%)	Transverse Modulus, GPa (Msi)	Transverse Strength, MPa (ksi)
E-glass-epoxy	20	39	8.61 (1.25)	47.2 (6.85)
		67	18.89 (2.74)	30.87 (4.48)
E-glass-epoxy	24	46	8.96 (1.30)	69.1 (10.03)
		57	13.23 (1.92)	77.92 (11.31)
		68	21.91 (3.18)	67.93 (9.86)
		73	25.9 (3.76)	41.27 (5.99)

Source: Adapted from Adams, D.F. and Doner, D.R., *J. Compos. Mater.*, 1, 152, 1967.

LAMPIRAN 1

Daftar Pustaka


- Brøndsted, P., Nijssen, R.P.L., (2013), “Advances in wind turbine blade design and materials”, © Woodhead Publishing Limited, 2013
- Gamstedt, E.K., Talreja, R. (1999), “Fatigue damage mechanisms in unidirectional carbon fibre-reinforced plastics”, *Journal of Materials Science*, no. 34, 1999, pp. 2535-2546
- Harper, C.A., Petrie, E.M. (2003), “PLASTICS MATERIALS AND PROCESSES: A Concise Encyclopedia “, Copyright © 2003 John Wiley & Sons, Inc
- Mallick, P.K. (2007), “FIBER REINFORCED COMPOSITES: Materials, Manufacturing, and Design”, 2007 by Taylor & Francis Group, LLC
- Samborsky, D.D., Mandell, J.F., Agastra, P. (2016), “SNL/MSU/DOE COMPOSITE MATERIAL FATIGUE DATABASE: Mechanical Properties of Composite Materials for Wind Turbine Blades”, Version 25.0; April 7, 2016, Montana State University - Bozeman
<http://energy.sandia.gov/energy/renewable-energy/wind-power/materials-reliability-standards/>
- Nijssen, R.P.L. (2015), “Composite Materials: An Introduction”, 1st English edition, based on 3rd Dutch edition (ISBN: 978-90-77812-51-8), Copyright©2015 R.P.L. Nijssen, Inholland University of Applied Sciences.
- Tong, W., (2010), “Wind Power Generation and Wind Turbine Design”, WIT Press Ashurst Lodge, Ashurst, Southampton, SO40 7AA, UK

LAMPIRAN 1


(Halaman ini sengaja dikosongkan)

LAMPIRAN 2

Kurva $P-S-N$ Data Hasil Eksperimen Dan Umur Kelelahan Prediksi NN Yang Diterima




Gambar L2.1. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = 0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.2. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.3. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -1$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.4. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 1 dengan $R = -2$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.5. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = -0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.6. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = -1$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.7. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = -2$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.8. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 1 dengan $R = 10$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.9. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = -0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.10. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = -1$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.11. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = -2$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.12. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 1 dengan $R = 10$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.13. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.14. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.7$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.15. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.8$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.16. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 0.9$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.17. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = -0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.18. Kurva $P-S-N$ hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = -2$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.19. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-GA) untuk material 2 dengan $R = 10$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.20. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.21. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.7$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.22. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.8$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.23. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 0.9$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.24. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = -0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.25. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = -2$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.26. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-DE) untuk material 2 dengan $R = 10$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.27. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

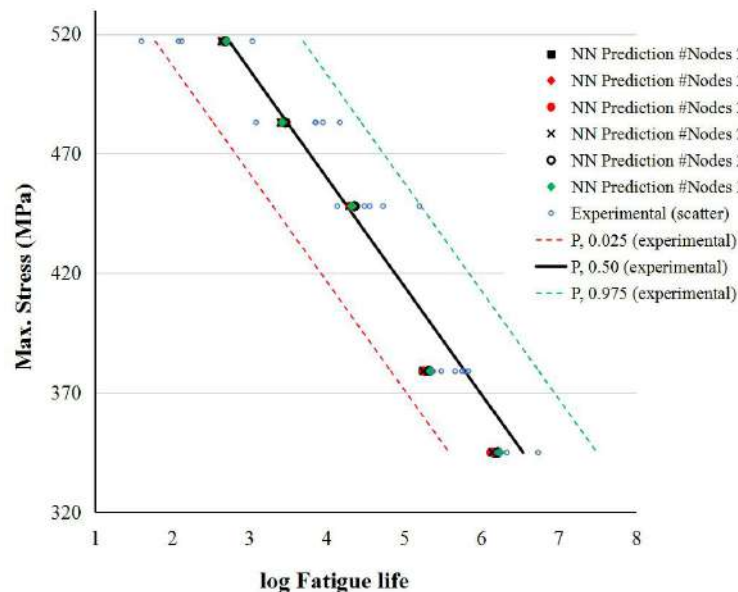


Gambar L2.28. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.7$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.29. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.8$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.




Gambar L2.30. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 0.9$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2




Gambar L2.31. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = -0.5$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.



Gambar L2.32. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = -2$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2



Gambar L2.33. Kurva P - S - N hasil data eksperimental dan plot data prediksi NN (MLP-PSO) untuk material 2 dengan $R = 10$. Kurva disusun dari data (*scatter*) yang terdistribusi normal dengan tingkat kepercayaan 95%.

LAMPIRAN 2

(Halaman ini sengaja dikosongkan)

LAMPIRAN 3

Teori Test ANOVA Dan Tukey (Minitab)

(Halaman ini sengaja dikosongkan)

[One-Way ANOVA](#)[Before you start](#)[Overview](#)[Data considerations](#)[Example](#)[Perform the analysis](#)[Enter your data](#)[Select the analysis options](#)[Select the group comparisons](#)[Select the graphs to display](#)[Select the results to display](#)[Store statistics](#)[Interpret the results](#)[Key results](#)[All statistics and graphs](#)[Methods and formulas](#)[Model](#)[Fits and residuals](#)**Sumber:**<https://support.minitab.com/en-us/minitab/18/help-and-how-to/modeling-statistics/anova/how-to/one-way-anova/methods-and-formulas/multiple-comparisons/>

Methods and formulas for multiple comparisons in One-Way ANOVA

[Learn more about Minitab 18](#)

Select the method or formula of your choice.

Minitab offers five different methods for comparing multiple factor means in one-way analysis of variance: Tukey's, Fisher's, Dunnett's, Hsu's MCB, and Games-Howell. The formulas for these tests are listed below.

Notation

Term	Description
\bar{y}_i	the sample mean for the i^{th} factor level
\bar{y}_j	the sample mean j^{th} factor level
n_i	the number of observations in level i
r	the number of levels
s	the pooled standard deviation or $\sqrt{\text{MSE}}$
u	the degrees of freedom for error
α	the simultaneous probability of making a Type I error
α^*	the individual probability of making a Type I error

Tukey:

$$\bar{y}_i - \bar{y}_j \pm \frac{Q(1 - \alpha; r, n_T - r)}{\sqrt{2}} s \sqrt{\frac{1}{n_i} + \frac{1}{n_j}}$$

where Q = upper α percentile of the studentized range distribution with r and $n_T - r$ degrees of freedom.

To find the individual error rate from the simultaneous error rate, use the following formula:

$$\alpha^* = 2[1 - P(t_u \leq \frac{1}{\sqrt{2}} Q_{1-\alpha, r, n_T-r})]$$

Fisher:

$$\bar{y}_i - \bar{y}_j \pm t_{1-\frac{\alpha^*}{2}, n_T-r} s \sqrt{\left(\frac{1}{n_i} + \frac{1}{n_j}\right)}$$

where t = upper $\alpha/2$ point of the Student's t -distribution with u df.

To find the simultaneous confidence level from the individual error rate, use the following formula:

$$\text{Simultaneous Confidence Level} = 1 - \alpha = P(Q \leq \sqrt{2} \times t_{1-\alpha^*/2, u})$$

Dunnett:

$$\bar{y}_i - \bar{y}_j \pm |d| s \sqrt{\frac{1}{n_i} + \frac{1}{n_j}}$$

To see how d is calculated, refer to page 63 in Hsu¹.

Hsu's MCB:

We give formulas for the case where all group sizes are equal to n . Formulas for unequal group sizes are found in Hsu¹. Suppose you chose the best to be the largest mean, and you want the confidence interval for the i^{th} mean minus the largest of the others.

The lower endpoint is the smaller of zero and

$$\bar{y}_j - m_{ax} \quad \bar{y}_j - ds\sqrt{2/n}$$

The upper endpoint is the larger of zero and

$$\bar{y}_j - m_{ax} \quad \bar{y}_j + ds\sqrt{2/n}$$

To see how d is calculated, refer to page 83 in Hsu¹.

When the best is the smallest of the level means, the formulas are the same, except that max is replaced by min.

Games-Howell and Welch Test

The Welch test statistic is computed as follows.

$$F = \frac{\left[\frac{1}{k-1} \sum_{i=1}^k W_i (\bar{y}_i - \bar{y}_{..})^2 \right]}{\left\{ 1 + \frac{2(k-2)}{k^2-1} \left[\sum_{i=1}^k \frac{\left(1 - \frac{W_i}{W}\right)^2}{n_i - 1} \right] \right\}}$$

The p-value for the Welch test is an upper tail probability for an F distribution with numerator degrees of freedom k - 1, where k is the number of X levels, and denominator degrees of freedom given by:

$$df = \frac{k^2 - 1}{3 \sum_{i=1}^k \frac{\left(1 - \frac{W_i}{W}\right)^2}{n_i - 1}}$$

The comparison interval for $\mu_i - \mu_j$ is

$$\bar{y}_i - \bar{y}_j \pm \frac{Q_{\alpha, k, \hat{\nu}_{ij}}}{\sqrt{2}} \left(\frac{s_i^2}{n_i} + \frac{s_j^2}{n_j} \right)^{\frac{1}{2}}$$

The critical value is based on the Studentized range (Q) for k groups, similar to the Tukey-Kramer intervals. But for Games-Howell, Minitab computes different degrees of freedom for each comparison:

$$\hat{\nu}_{ij} = \frac{\left(\frac{s_i^2}{n_i} + \frac{s_j^2}{n_j} \right)^2}{\left(\frac{s_i^2}{n_i} \right)^2 \frac{1}{n_i - 1} + \left(\frac{s_j^2}{n_j} \right)^2 \frac{1}{n_j - 1}}$$

The T-ratio used to compute the adjusted P-value equals:

$$\frac{\bar{Y}_i - \bar{Y}_j}{\left(\frac{s_i^2}{n_i} + \frac{s_j^2}{n_j} \right)^{\frac{1}{2}}}$$

Where:

The j^{th} response in the i^{th} level of the categorical factor equals:

$Y_{ij}, j = 1, \dots, n_i; i = 1, \dots, k$

The average response at the i^{th} level equals:

$$\bar{Y}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} Y_{ij}$$

The sample variance equals:

$$s_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2$$

The weight for level i equals:

$$w_i = \frac{n_i}{s_i^2}$$

The sum of all weights equals:

$$W = \sum_{i=1}^k w_i$$

The overall weighted average of responses equals:

$$\bar{Y}_{..} = \frac{1}{W} \sum_{i=1}^k w_i \bar{Y}_i$$

Acknowledgment

We are very grateful for assistance in the design and implementation of multiple comparisons from Jason C. Hsu.

[1] J.C. Hsu (1996). Multiple Comparisons, Theory and methods. Chapman & Hall.

[Minitab.com](#) • [License Portal](#) • [Store](#) • [Blog](#) • [Contact Us](#)

Copyright © 2017 Minitab Inc. All rights Reserved.

English

How-To
Two-Way ANOVA
Before you start
Overview
Data considerations
Example
Perform the analysis
Enter your data
Select the residual plots
Interpret the results
Key results
All statistics and graphs
Methods and formulas
Methods and formulas

Search Minitab Express Support

Sumber:

<http://support.minitab.com/en-us/minitab-express/1/help-and-how-to/modeling-statistics/anova/how-to/two-way-anova/methods-and-formulas/methods-and-formulas/#p-value-analysis-of-variance-table>

Methods and formulas for Two-way ANOVA

[Learn more about Minitab](#)

Select the method or formula of your choice.

In This Topic

[Adj MS](#)

[Adj SS](#)

[Degrees of freedom \(DF\)](#)

[Fitted mean](#)

[Fit](#)

[F-value](#)

[Pooled standard deviation](#)

[P-value – Analysis of variance table](#)

[Residuals \(Resid\)](#)

[R-sq](#)

[R-sq \(adj\)](#)

[R-sq \(pred\)](#)

[S](#)

[SE Mean](#)

[Standardized residual \(Std Resid\)](#)

Adj MS

The calculations for the mean square for the factors, interaction, and error follow:

$$MS(A) = \frac{SS(A)}{DF(A)}$$

$$MS(B) = \frac{SS(B)}{DF(B)}$$

$$MS(AB) = \frac{SS(AB)}{DF(AB)}$$

$$MS\ Error = \frac{SS\ Error}{DF\ Error}$$

Notation

Term	Description
MS	Mean Square
SS	Sum of Squares
DF	Degrees of Freedom

Adj SS

The sum of squared distances. SS Total is the total variation in the data. SS (A) and SS (B) are the amount of variation of the estimated factor level mean around the overall mean. These statistics are also known as the sum of squares for factor A or factor B. SS Error is the amount of variation of the observations from their fitted values. The calculations follow:

- $SS(A) = nb \sum_i (\bar{y}_{i..} - \bar{y} \dots)^2$
- $SS(B) = na \sum_j (\bar{y}_{.j.} - \bar{y} \dots)^2$
- $SS(AB) = SS\ Total - SS\ Error - SS(A) - SS(B)$
- $SS\ Error = \sum_i \sum_j \sum_k (y_{ijk} - \bar{y}_{ij.})^2$
- $SS\ Total = \sum_i \sum_j \sum_k (y_{ijk} - \bar{y} \dots)^2$

Term	Description
a	number of levels in factor A
b	number of levels in factor B
n	total number of trials
$y_{i..}$	mean of the i^{th} factor level of factor A
$y \dots$	overall mean of all observations
$y_{.j.}$	mean of the j^{th} factor level of factor B



y_{ij} , mean of observations at the i^{th} level of factor A and the j^{th} level of factor B

Degrees of freedom (DF)

For a model with factors A and B, the degrees of freedom associated with each sum of squares follow:

- $DF(A) = a - 1$
- $DF(B) = b - 1$
- $DF(AB) = (a - 1)(b - 1)$
- With no interaction in the model, $DF \text{ Error} = (n - 1) - (a - 1) - (b - 1)$
- With the interaction in the model, $DF \text{ Error} = (n - 1) - (a - 1) - (b - 1) - (a - 1)(b - 1)$
- $\text{Total} = n - 1$

Notation

Term	Description
a	number of levels in factor A
b	number of levels in factor B
n	total number of observations

Fitted mean

The fitted means are least squares estimates. For a factor level, the least squares mean is the sum of the constant coefficient and the coefficient for the factor level.

$$\bar{y}_i = \hat{\mu} + \hat{\alpha}_i$$

For a combination of factor levels in an interaction term, the least squares mean is the same as the fitted value.

$$\bar{y}_{ij} = \hat{\mu} + \hat{\alpha}_i + \hat{\beta}_j$$

The equation that defines the vector of estimated coefficients is as follows:



$$\hat{\beta} = (X'X)^{-1}X'Y$$

In the case of balanced data, the fitted means are equivalent to means in the data. For a factor level, the fitted mean is as follows:

$$\bar{y}_j = \frac{\sum_{i=1}^{n_j} y_{ij}}{n_j}$$

For a combination of levels in an interaction term, the fitted mean is the same as the fitted value.

$$\bar{y}_{jk} = \frac{\sum_{i=1}^{n_{ij}} y_{ijk}}{n_{ij}}$$

Notation

Term	Description
$\hat{\mu}$	constant coefficient
$\hat{\alpha}_i$	coefficient for the i^{th} level of a factor
$\hat{\beta}_j$	coefficient for the j^{th} level of the second factor
X	design matrix
X'	transpose of the design matrix
$(X'X)^{-1}$	inverse of the $X'X$ matrix
Y	vector of response values
y_{ij}	i^{th} value at the j^{th} level of the factor
n_i	sample size for the j^{th} level of the factor
y_{ijk}	i^{th} value at the j^{th} level of the first factor and the k^{th} level of the second factor
n_{jk}	sample size for the j^{th} level of the first factor and the k^{th} level of the second factor

Fit

The fitted values are least squares estimates.



$$\hat{y} = \mathbf{X}\hat{\beta}$$

The equation that defines the vector of estimated coefficients is as follows:

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

In the case of balanced data, the fitted values are equivalent to means in the data. If the model has no interaction term, the fitted value is as follows:

$$\hat{y}_{ijk} = \bar{y}_{i..} + \bar{y}_{.j.} - \bar{y}_{...}$$

If the model has an interaction term, the fitted value is the cell mean, or the mean of observations at the i^{th} level of factor A and the j^{th} level of factor B.

$$\hat{y}_{ijk} = \bar{y}_{ij.}$$

Notation

Term	Description
\mathbf{X}	design matrix
\mathbf{X}'	transpose of the design matrix
$(\mathbf{X}'\mathbf{X})^{-1}$	inverse of the $\mathbf{X}'\mathbf{X}$ matrix
\mathbf{Y}	vector of response values
$\bar{y}_{i..}$	mean of the observations at the i^{th} level of factor A
$\bar{y}_{.j.}$	mean of the observations at the j^{th} level of factor B
$\bar{y}_{...}$	mean of all of the observations
$\bar{y}_{ij.}$	mean of the observations at the i^{th} level of factor A and the j^{th} level of factor B

F-value

The F statistic depends on the term in the test. For factor A, the F-statistic is as follows:

$$F(A) = \frac{MS(A)}{MS(Error)}$$

For factor B, the F-statistic is as follows:



$$F(B) = \frac{MS(B)}{MS(Error)}$$

For the interaction between factor A and factor B, the F-statistic is as follows:

$$F(AB) = \frac{MS(AB)}{MS(Error)}$$

When the lack-of-fit test appears, the F-statistic is as follows:

$$F(\text{Lack-of-fit}) = \frac{MS(\text{Lack-of-fit})}{MS(\text{Pure error})}$$

The numerator and denominator degrees of freedom correspond to the degrees of freedom for the mean square.

Notation

Term	Description
MS	Mean Square

Pooled standard deviation

The pooled standard deviation is equivalent to S, which is displayed in the output. The formula follows:

$$S = \sqrt{MS \text{ Error}}$$

Notation

Term	Description
MS	Mean Square

P-value – Analysis of variance table

The degrees of freedom for the F statistic that you use to calculate the p-value depend on the term that is in the test.

When you test a term, the denominator degrees of freedom are always the degrees of freedom

error. The degrees of freedom for error depend on whether the interaction term is in the model or not.

- With no interaction in the model, $DF\ Error = (n - 1) - (a - 1) - (b - 1)$
- With the interaction in the model, $DF\ Error = (n - 1) - (a - 1) - (b - 1) - (a - 1)(b - 1)$

When you test a term, the numerator degrees of freedom depend on the term.

- For $F(A)$, the degrees of freedom for the numerator are $a - 1$
- For $F(B)$, the degrees of freedom for the numerator are $b - 1$
- For $F(AB)$, the degrees of freedom for the numerator are $(a - 1)(b - 1)$

For the lack-of-fit test, the degrees of freedom follow:

- Denominator $DF = n - c$
- Numerator $DF = c - p$

Formula

$$1 - P(F \leq f_j)$$

Notation

Term	Description
a	number of levels in factor A
b	number of levels in factor B
n	total number of observations
c	number of unique combinations of factor levels
p	number of terms in the model
$P(F \leq f_j)$	cumulative distribution function for the F distribution
f_j	f statistic for the test

Residuals (Resid)

$$e_{ijk} = y_{ijk} - \hat{y}_{ijk} = y_{ijk} - \bar{y}_{ij}$$



Notation

Term	Description
y_{ijk}	k^{th} response value for the i^{th} level of factor A and the j^{th} level of factor B
\hat{y}_{ijk}	k^{th} fitted value for the i^{th} level of factor A and the j^{th} level of factor B
$\bar{y}_{ij\cdot}$	mean of the fitted values for the i^{th} level of factor A and the j^{th} level of factor B

R-sq

R^2 is also known as the coefficient of determination.

Formula

$$R^2 = 1 - \frac{SS \text{ Error}}{SS \text{ Total}} = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

Notation

Term	Description
y_i	i^{th} observed response value
\bar{y}	mean response
\hat{y}_i	i^{th} fitted response

R-sq (adj)

Accounts for the number of predictors in your model and is useful for comparing models with different numbers of predictors.

Formula

$$R^2_{\text{adj}} = 1 - \frac{MS \text{ Error}}{MS \text{ Total}} = 1 - \left(\frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \right) \left(\frac{n-1}{n-p-1} \right)$$



Notation

Term	Description
y_i	i^{th} observed response value
\hat{y}_i	i^{th} fitted response
\bar{y}	mean response
n	number of observations
p	number of model parameters

R-sq (pred)

$$R^2(\text{pred}) = 1 - \frac{\text{PRESS}}{\text{SS Total}} = 1 - \frac{\sum_{i=1}^n \left(\frac{e_i}{1 - h_i} \right)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

While the calculations for $R^2(\text{pred})$ can produce negative values, Minitab displays zero for these cases.

Notation

Term	Description
y_i	i^{th} observed response value
\bar{y}	mean response
n	number of observations
e_i	i^{th} residual
h_i	i^{th} diagonal element of $X(X'X)^{-1}X'$
X	design matrix

S

$$s = \sqrt{\text{MSE}}$$



Notation

Term	Description
MSE	mean square error

SE Mean

Formula

$$\sqrt{s^2(\mathbf{x}'_0(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_0)}$$

The vector \mathbf{x}_0 defines the factor levels for a fitted mean in the same terms as the design matrix. The vector has 1 for the constant coefficient, the combination of 1, 0, and -1 that defines the factor levels for the term, and 0 for any factor levels that are not in the term. For the highest-level interaction in the model, all of the elements in the vector define factor levels and the standard error of the mean equals the standard error of the fitted value.

Notation

Term	Description
s^2	mean square error
\mathbf{X}	design matrix
\mathbf{X}'	transpose of the design matrix
$(\mathbf{X}'\mathbf{X})^{-1}$	inverse of the $\mathbf{X}'\mathbf{X}$ matrix
\mathbf{x}_0	vector that defines the factor levels for the fitted mean
\mathbf{x}'_0	transpose of the vector that defines the factor levels for the fitted mean

Standardized residual (Std Resid)

Standardized residuals are also called "internally Studentized residuals."

Formula



$$r_i = \frac{e_i}{\sqrt{s^2(1 - h_i)}}$$

Notation

Term	Description
e_i	i^{th} residual
h_i	i^{th} diagonal element of $X(X'X)^{-1}X'$
s^2	mean square error
X	design matrix
X'	transpose of the design matrix

[Minitab.com](#) • [License Portal](#) • [Store](#) • [Blog](#) • [Contact Us](#)

Copyright © 2016 Minitab Inc. All rights Reserved.

BIOGRAFI PENULIS



Penulis lahir di Surakarta pada tahun 1976. Menyelesaikan MI/SD, SMP dan SMA Muhammadiyah di kabupaten Boyolali, Jawa Tengah. Pendidikan S1 ditempuh di Teknik Mesin ITS, Bidang Studi Desain (lulus 2001) dengan minat penelitian pada getaran dan bising. Selama menjadi mahasiswa S1 aktif di beberapa kegiatan dan organisasi kemahasiswaan di lingkungan jurusan, serta menjadi Grader di laboratorium tenaga hidrolik dan beberapa kelas responsi. Berpengalaman selama lebih dari 14 tahun di dunia industri manufaktur di bidang fabrikasi alat angkat dan angkut, boiler, perpipaan, struktur, bejana tekan, HRSG, dan sebagainya, serta di proyek EPCC pembangunan PLTP. Selama berkarir berpengalaman di beberapa posisi, antara lain desain *crane* dan *conveyor*, *manufacturing process engineer*, *quality engineer*, *detail engineering manager*, *project quality manager*, *quality assurance manager* dan *quality control manager*. Minat penulis adalah di bidang kelelahan material, *fracture mechanic*, *reliability*, komposit, pemodelan, *artificial neural network* dan optimasi.